

DARLY GERALDO DE SENA JÚNIOR

**SISTEMA DE VISÃO ARTIFICIAL PARA IDENTIFICAÇÃO DE
PLANTAS DE MILHO ATACADAS PELA
LAGARTA DO CARTUCHO (*Spodoptera frugiperda*)**

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

APROVADA: 22 de fevereiro de 2002.

Prof. Nerilson Terra Santos

Prof. Carlos Antônio Álvares Soares Ribeiro

Prof. Daniel Marçal de Queiroz
(Conselheiro)

Dr. Reinaldo Lúcio Gomide
(Conselheiro)

Prof. Francisco de Assis de Carvalho Pinto
(Orientador)

A meus pais e minhas irmãs, pelo apoio em todos os momentos.

A meus avós.

Às pessoas com quem convivi.

AGRADECIMENTOS

A Deus, por todas as oportunidades.

À Universidade Federal de Viçosa e ao Departamento de Engenharia Agrícola, pela oportunidade de realização do curso.

À Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) pelo financiamento concedido durante o curso de mestrado.

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.

Ao Professor Francisco de Assis de Carvalho Pinto pela orientação, dedicação, amizade e confiança.

Ao Professor Daniel Marçal de Queiroz, pela orientação e amizade.

Aos Professores Mauri Martins Teixeira, ao Dr. Reinaldo Lúcio Gomide e ao Professor Nerilson Terra Santos pelo auxílio e valiosas sugestões no decorrer do trabalho.

Ao Professor Carlos Antônio Álvares Soares Ribeiro.

Aos pesquisadores da Embrapa milho e sorgo Dr. Evandro Mantovani e Dr. Paulo Afonso Viana.

Aos Professores do Departamento de Engenharia Agrícola.

Aos funcionários da Embrapa Milho e Sorgo, especialmente do NIASA e da área de entomologia agrícola.

Aos funcionários do Laboratório de Mecanização Agrícola e do Departamento de Engenharia Agrícola

Aos colegas do Laboratório de Projeto de Máquinas e Visão Artificial Leidy, Alisson, Cristiano, Kalil, Roberto Carlos e Varella, aos estagiários Enrique, Rodrigo, Eduardo, Renata e Alexandre, aos colegas de curso Denilson, Donizette, Elton, Gilton, Jean, João Paulo, Luciano, Luizinho, Paulo, Ricardo e Sebastião pelo auxílio, amizade e bom convívio.

A meus pais e irmãs pelo apoio constante.

À D.Sônia, Sr. Diógenes, Zana e Evandro pela amizade e incentivo para realização deste trabalho.

À Tatiana pelo carinho, estímulo, amizade e compreensão nas dificuldades e nos bons momentos durante o curso.

Sinceros agradecimentos a todos que colaboraram para que este trabalho fosse realizado.

BIOGRAFIA

DARLY GERALDO DE SENA JÚNIOR, filho de Ana Maria de Araújo Sena e Darly Geraldo de Sena, nasceu em Registro, SP, no dia 19 de julho de 1968.

Em março de 1990 concluiu o curso de Agronomia na Universidade Federal de Viçosa e em janeiro de 1993 concluiu o curso de Zootecnia na mesma universidade

Em março de 2000 iniciou o curso de Mestrado em Engenharia Agrícola, Área de concentração em Mecanização Agrícola, na Universidade Federal de Viçosa.

Em fevereiro de 2002, submeteu-se à defesa de tese.

ÍNDICE

RESUMO.....	viii
ABSTRACT	x
INTRODUÇÃO	1
LITERATURA CITADA	6
EFEITO DA ILUMINAÇÃO SOBRE A SEGMENTAÇÃO DE IMAGENS DE PLANTAS DE MILHO ATACADAS PELA LAGARTA DO CARTUCHO (<i>Spodoptera frugiperda</i>)	8
RESUMO.....	8
LIGHT INTENSITY EFFECTS ON IMAGE SEGMENTATION OF DAMAGED CORN PLANTS BY FALL ARMYWORM (<i>Spodoptera frugiperda</i>).....	8
ABSTRACT	8
INTRODUÇÃO	9
MATERIAL E MÉTODOS.....	13
RESULTADOS E DISCUSSÃO.....	15
CONCLUSÕES	20
AGRADECIMENTOS	20
LITERATURA CITADA	20
AVALIAÇÃO DE MÉTODOS AUTOMÁTICOS DE LIMIAÇÃO PARA IMAGENS DE PLANTAS DE MILHO ATACADAS PELA LAGARTA DO CARTUCHO (<i>Spodoptera frugiperda</i>)	23
RESUMO.....	23
AUTOMATIC THRESHOLD EVALUATION ON FALL ARMYWORM (<i>Spodoptera frugiperda</i>) DAMAGED CORN PLANT IMAGES	23
ABSTRACT	23
INTRODUÇÃO	24
MATERIAL E MÉTODOS.....	27
RESULTADOS E DISCUSSÃO.....	32
CONCLUSÕES	36
AGRADECIMENTOS	36
LITERATURA CITADA	37
IDENTIFICAÇÃO DE PLANTAS DE MILHO ATACADAS PELA LAGARTA DO CARTUCHO (<i>Spodoptera frugiperda</i>) EM IMAGENS COLORIDAS DIGITAIS.....	40
RESUMO.....	40
FALL ARMYWORM (<i>Spodoptera frugiperda</i>) DAMAGED CORN PLANT IDENTIFICATION ON DIGITAL IMAGES.....	40
ABSTRACT	40
INTRODUÇÃO	41
MATERIAL E MÉTODOS.....	45

RESULTADOS E DISCUSSÃO.....	49
CONCLUSÕES	52
AGRADECIMENTOS	53
LITERATURA CITADA	53
CONCLUSÕES GERAIS.....	57
APÊNDICES	59
Apêndice A - Código-fonte do algoritmo implementado no MATLAB, para processamento das imagens utilizando o índice do excesso de verde normalizado.....	60
Apêndice B - Código-fonte do algoritmo implementado no MATLAB, para obtenção dos valores dos limiares manuais	61
Apêndice C - Código-fonte do algoritmo implementado no MATLAB, para obtenção das imagens binárias utilizando o algoritmo iterativo	62
Apêndice D - Código-fonte do algoritmo implementado no MATLAB, para obtenção das imagens binárias utilizando o algoritmo bayesiano	64
Apêndice E - Código-fonte do algoritmo implementado no MATLAB, para obtenção das imagens-diferença entre as imagens binárias dos limiares manuais e as imagens binárias dos limiares automáticos	68
Apêndice F - Código-fonte do algoritmo implementado no MATLAB, para classificação das imagens de acordo com o número de objetos em blocos das imagens	69

RESUMO

SENA JÚNIOR, Darly Geraldo de, M.S., Universidade Federal de Viçosa, fevereiro de 2002.
Identificação de plantas de milho atacadas pela lagarta do cartucho (*Spodoptera frugiperda*) utilizando imagens coloridas digitais. Orientador: Francisco de Assis de Carvalho Pinto. Conselheiros: Daniel Marçal de Queiroz, Reinaldo Lúcio Gomide e Mauri Martins Teixeira.

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. A lagarta do cartucho (*Spodoptera frugiperda*) é uma das pragas mais importantes na cultura do milho, no Brasil, sendo controlada, principalmente, por meio de produtos químicos. Acredita-se que o controle pode ser realizado de forma localizada, com auxílio de um sistema de visão artificial. O objetivo do presente trabalho foi desenvolver e avaliar um algoritmo para identificação de plantas de milho atacadas pela lagarta do cartucho, utilizando imagens coloridas digitais. Foram obtidas imagens de plantas atacadas e não atacadas por esse inseto, em oito épocas correspondentes a diferentes dias após a infestação, e em três intensidades de iluminação. Os valores do limiar manual para segmentação das folhas nas imagens foram analisados estatisticamente, para verificar a influência desses fatores e a eficácia de um índice de cor utilizado para redução do efeito da variação da intensidade luminosa. Foram implementados ainda dois métodos automáticos de limiarização, sendo o resultado comparado com a limiarização manual das mesmas plantas. O algoritmo proposto consistiu de duas etapas, processamento e análise das imagens. Na primeira etapa, realizou-se o processamento para obtenção de imagens binárias, em que as folhas das plantas foram segmentadas dos demais pixels. Na segunda etapa, as imagens binárias foram divididas em blocos e, de acordo com o número de grupos de pixels conectados (objetos), promoveu-se a classificação das imagens como de plantas atacadas ou não atacadas. Os resultados mostraram que os limiares diferiram para as imagens obtidas em

intensidades luminosas e em épocas diferentes, o que dificulta a utilização de um limiar constante. Os resultados obtidos pelos dois métodos automáticos de limiarização foram satisfatórios, com média acima de 99% de exatidão global, o que demonstra que ambos têm potencial para serem utilizados em um sistema de identificação de plantas de milho atacadas pela lagarta do cartucho. O algoritmo proposto classificou, corretamente, 94,72 % das imagens testadas.

ABSTRACT

SENA JÚNIOR, Darly Geraldo de, M.S., Universidade Federal de Viçosa, february of 2002.
Fall Armyworm (*Spodoptera frugiperda*) damaged corn plant identification on digital images. Adviser: Francisco de Assis de Carvalho Pinto. Committee members: Daniel Marçal de Queiroz, Reinaldo Lúcio Gomide e Mauri Martins Teixeira.

Precision agriculture looks up to adjust the agricultural practices to the parcel demands and productive potential to maximize the profit, rationalize the use of the production factors and reduce the environmental damage. The fall armyworm (*Spodoptera frugiperda*) is one of the most important corn pests in Brazil and the use of chemicals is the main control method. It is believed that a site specific control can be done by a machine vision system. The objective of this work was to develop and evaluate an algorithm for identifying damaged corn plants by the fall armyworm using digital color images. The used images were of damaged and not damaged corn plants in eight stages taken in three light intensities. The values of manual thresholds to segment the leaves from the background were compared for verifying these factor influence and the efficacy of an index to reduce light intensity variation. It was also implemented two automatic threshold methods and their results compared to the manual threshold of the same images. The proposed algorithm presented two stages: processing and image analysis. On the first stage, the images were processed to create binary images where the pixel leaves were segmented from the other pixels. On the second stage, the images were subdivided into blocks and classified into damaged or not damaged depending on the number of objects found in each block. The thresholds differed for the images obtained in different light intensities and in different stages, thus the use of a constant threshold could not be efficient. The results of both automatic methods were considered satisfactory by presenting average accuracy higher than 99%, showing potential to be used by a system for identifying the damaged corn plants. The proposed algorithm presented overall accuracy of 94,72%.

INTRODUÇÃO

A agricultura de precisão pode ser conceituada como a habilidade em monitorar e acessar a atividade agrícola, localizadamente, com o objetivo de aumentar a eficiência do processo produtivo (Queiroz et al., 2000). No manejo das áreas agrícolas de acordo com a exigência média dos talhões podem ocorrer aplicações excessivas de insumos em algumas áreas, com desperdício de recursos e maior possibilidades de contaminação ambiental, ou a aplicação de subdoses, deixando-se de explorar todo o potencial produtivo da parcela. A aplicação localizada de insumos em agricultura de precisão baseia-se, principalmente, em dois métodos, isto é, uso de mapas e, ou resposta de sensores em tempo real. O sistema baseado em mapas requer a localização exata do equipamento na área, normalmente por meio de um sistema de posicionamento global (GPS), além de um programa computacional capaz de acessar o mapa de prescrição e determinar a dosagem adequada àquele local específico. Os sistemas de sensores em tempo real utilizam sensores capazes de determinar as propriedades do solo e da cultura à medida que a máquina desloca, com os dados obtidos utilizados automaticamente para ajustar a dosagem dos insumos.

A viabilidade econômica da tecnologia de agricultura de precisão é o principal fator condicionante à sua adoção generalizada. Além disso, para que se justifique sua implementação, três critérios básicos devem ser atendidos: a existência de variabilidade espacial nos fatores que afetam a produtividade, a possibilidade de identificar e mensurar a causa dessa variabilidade e que as informações dessas medições possam ser utilizadas para modificar as práticas de manejo e aumentar o lucro, ou reduzir o impacto ambiental (Plant, 2001). Embora algumas tecnologias empregadas no sistema baseado em mapas estejam disponíveis, tais como o GPS, os monitores de produtividade em colhedoras de grãos e os sistemas de informações geográficas (SIG), o uso de sensores ainda requer desenvolvimento.

A lagarta do cartucho (*Spodoptera frugiperda*) é considerada uma das pragas mais importantes na cultura do milho no Brasil (Cruz,1995), com o grau de dano variável de acordo com a época de semeadura, clima, estado nutricional da lavoura e estágio fenológico da planta (Fancelli e Dourado Neto, 2000). O controle da lagarta do cartucho é realizado principalmente por meio de produtos químicos, aplicados utilizando-se pulverizador costal ou tratorizado (Carvalho, 1987), tratamento de sementes (Oliveira & Silva, 1994) e via água de irrigação (Viana & Costa, 1994). Entretanto, os produtos utilizados, normalmente, ocasionam a eliminação dos agentes naturais de controle graças ao seu amplo espectro de ação (Cruz et al., 2000).

As estratégias do manejo integrado de pragas (MIP) visam monitorar a população das pragas objetivando a aplicação de medidas de controle quando se atinge o nível de dano econômico, ou seja, o custo de controle é inferior ao dano provocado pela praga. No caso da lagarta do cartucho na cultura do milho, essas medidas são recomendadas de acordo com a percentagem de plantas atacadas, identificadas visualmente por pessoal treinado. O MIP tem sido utilizado, estimando-se a densidade populacional média da praga por lavoura ou talhão; entretanto, geralmente, a distribuição espacial de pragas ocorre de maneira agregada ou em reboleira (Viana, 2000). A resistência de insetos aos produtos utilizados em seu controle é uma grande preocupação na área agrícola, uma vez que a utilidade dos inseticidas tem sido limitada em razão da evolução da resistência a esses compostos em várias pragas (Guedes & Ribeiro, 2000). Resultados de um monitoramento da susceptibilidade de populações de *S. frugiperda* a inseticidas, tradicionalmente utilizados no Brasil, indicaram a necessidade de implementação de um programa de manejo da resistência dessa praga na cultura do milho (Omoto et al., 2000).

A utilização do manejo integrado de pragas agrícolas em sítio específico pode tornar-se um mecanismo para retardar o desenvolvimento de resistência das pragas aos defensivos e conservar a população de inimigos naturais, criando refúgios sem aplicação de inseticidas dentro dos campos agrícolas. Campos de batata, tratados de acordo com o MIP convencional, apresentaram aumento significativo na resistência do besouro-da-batata-do-colorado (*Leptinotarsa decemlineata*) ao inseticida, enquanto nos campos manejados de forma localizada pequena ou nenhuma resistência foi observada; além disso, as populações de inimigos naturais apresentaram-se maiores nos campos tratados de modo localizado (Midgarden et al., 1997). O controle localizado, além de preservar os genótipos suscetíveis, pode permitir a redução na aplicação de inseticidas, conforme demonstrado no trabalho de

Weiz et al. (1996), em que o manejo em sítio específico de pragas, na cultura da batata, reduziu a aplicação de inseticidas em 45 a 70%, dependendo da época do ano.

Na área agrícola, a tomada de decisão baseada em diagnósticos visuais é bastante comum, 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. A determinação do nível de infestação de lavouras de milho pela lagarta do cartucho é um exemplo típico, em que se realiza amostragem na lavoura, por pessoal treinado, identificando-se visualmente as plantas atacadas. 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). Este 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. As informações geradas pelo sistema podem ser armazenadas para utilização posterior como, por exemplo, a elaboração de um mapa de prescrição, ou a geração de um sinal para controle de máquinas. As principais características de um SVA são a reprodutibilidade, a possibilidade de operar em ampla faixa do espectro de radiações eletromagnéticas e a capacidade de medir objetivamente a cor de objetos (Marques Filho & Vieira Neto, 1999). Embora na área agrícola a aplicação de SVA tem sido relativamente restrita, na indústria este sistema já é amplamente utilizado para inspecionar, classificar, medir ou localizar produtos (Thomas et al., 1995).

A complexidade das cenas é um desafio para o desenvolvimento de um SVA a ser utilizado na agricultura, pois, os produtos agrícolas apresentam grande variação na forma, tamanho e cor (Sadjadi, 1996). Outro fator importante é a variação na iluminação, em intensidade e cor, observada entre as diferentes épocas do ano e horários do dia (Steward & Tian, 1998). A intensidade luminosa e as sombras nas imagens são fatores que influenciam, diretamente, os valores dos pixels, pois estes representam a energia refletida pelos objetos que incide no sensor da câmera. A variação na temperatura de cor da luz, durante o dia, pode provocar alterações nas cores dos objetos. Somam-se, ainda, as dificuldades impostas pelo ambiente de trabalho dos equipamentos no campo, sujeitos a uma grande variação de temperatura, além da possibilidade de chuvas e poeira.

Um passo fundamental no processamento de imagens digitais é a segmentação, uma técnica em que se busca a distinção dos objetos de interesse dos demais constituintes da cena. Uma técnica amplamente utilizada é a limiarização, especialmente quando os valores dos pixels apresentam uma distribuição bimodal e o objetivo é uma imagem binária. Nesta

técnica, um valor de limiar é estabelecido e os pixels que apresentam valores inferiores e superiores ao limiar são agrupados nas duas classes. A limitação do emprego desta técnica em SVA é a variação observada na iluminação. Nessas condições, o limiar utilizado para agrupar os pixels pertencentes a um mesmo objeto deve ser dinâmico, ou o sistema deve utilizar técnicas capazes de minimizar os efeitos da variação de intensidade luminosa, permitindo trabalhar-se com um valor previamente definido.

Algumas técnicas são utilizadas para facilitar a segmentação, promovendo a redução dos efeitos da iluminação e o realce dos objetos de interesse na cena. A normalização é uma técnica usada para reduzir a variabilidade nos valores dos pixels na imagem e os efeitos da iluminação, combinando os valores originais dos pixels em mais de uma banda para gerar uma nova imagem (Andreadis & Tsalides, 1997). Em sensoriamento remoto, razão entre bandas e diversos índices são amplamente utilizados no intuito de reduzir a diferença de brilho em materiais idênticos, causada por diferenças na topografia do terreno, sombras ou mudanças sazonais no ângulo e intensidade da iluminação solar. Além disso, permite realçar características de interesse e reduzir o número de bandas necessárias à interpretação, concentrando a informação (Jensen, 1996). Uma vez que das imagens binárias serão extraídas as características dos objetos para classificação, é necessário utilizar um método de limiarização confiável e acurado para que a dimensão e a forma dos objetos na imagem binária seja consistente com a imagem original (Yang et al. 2001). A utilização de métodos automáticos na definição do limiar não só evitaria a influência de operadores, mas também tornaria mais rápida a escolha dos limiares no campo, onde a variação da iluminação influencia os valores dos pixels.

No Brasil, a lagarta do cartucho apresenta características que possibilitam seu controle localizado, com o auxílio de um sistema de visão artificial, beneficiando todo o sistema agrícola. A identificação de plantas atacadas pela lagarta do cartucho pode gerar informações para a elaboração de mapas de aplicação localizada de inseticidas ou, até mesmo, para o controle em tempo real de um pulverizador capaz de aplicar o produto somente nas plantas atacadas. Acredita-se que qualquer dos métodos apresenta potencial para redução do uso de inseticidas, da contaminação ambiental, do prejuízo à população de inimigos naturais e do desenvolvimento de resistência dessa praga aos produtos utilizados.

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), o “PRODETAB

030 – 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”. Neste contexto, o objetivo do presente trabalho foi desenvolver e avaliar um algoritmo para identificação de plantas de milho atacadas pela lagarta do cartucho, utilizando-se imagens coloridas digitais. O primeiro capítulo trata da avaliação estatística dos efeitos da intensidade luminosa, da presença ou não de injúrias provocadas pela lagarta do cartucho e do estágio de desenvolvimento das plantas sobre o valor de limiar mais adequado para segmentar as folhas das plantas de milho em imagens monocromáticas obtidas pelo processamento de imagens coloridas digitais. O segundo capítulo trata da implementação e avaliação de dois métodos de limiarização automática de imagens monocromáticas. O terceiro capítulo trata da implementação e avaliação do algoritmo para identificação de plantas atacadas pela lagarta do cartucho, utilizando-se imagens obtidas sob condições controladas.

LITERATURA CITADA

- Andreadis, I. & Tsalides, P. Analog computation of image chromaticity Real-Time Imaging, London, n.3, p.1 – 6, 1997.
- Carvalho, R.P.L. Pragas do Milho.in: Paterniani, E.; Viégas, G.P. (ed.) Melhoramento e Produção de Milho Fundação Cargill, Campinas SP v2 2 ed. p. 637 – 712 . 1987.
- Cruz, I. A lagarta do Cartucho na Cultura do Milho. Sete Lagoas: EMBRAPA-CNPMS,. 42P. (EMBRAPA-CNPMS. Circular Técnica, 21). 1995.
- Cruz, I.; Figueiredo, M.L.C.; Alberton, M. Eficiência de novos piretróides no controle da *Spodoptera frugiperda* em milho e seletividade ao predador *Doru luteipes* in: XXIII congresso nacional de milho e sorgo, resumos expandidos, Uberlândia, Associação Brasileira de Milho e Sorgo, 2000.
- Fancelli, A.L. & Dourado Neto, D. Produção de milho. 1 ed. Guaíba: Livraria e Editora Agropecuária, 2000, 360p.
- Guedes, R.N. & Ribeiro, B.M. Limitações de métodos de controle para o manejo de pragas. In: Manejo integrado – doenças, pragas e plantas daninhas. Zambolim, L (ed.) Viçosa, 2000.
- Jensen, J.R. Introductory digital image processing: a remote sensing perspective. New York: Prentice Hall, 1996, 318p.
- Marques Filho, O. & Vieira Neto, H. Processamento digital de imagens. Rio de Janeiro: Brasport, 1999, 406p.
- Midgarden, D.; Fleischer S.J.; Weisz, R.; Smilowitz, Z. Site-specific integrated pest management impact on development of esfenvalerate resistance in Colorado potato beetle (Coleoptera:Chrysomelidae) and on densities of natural enemies. Journal of Economic Entomology, Lanham n. 90 v. 4 p. 855-867, 1997.
- Oliveira, J.P.; Silva, A.L. Controle químico da lagarta do cartucho (*Spodoptera frugiperda*) em milho, com novo regulador de crescimento. In: XX Congresso Nacional de Milho e

- Sorgo, 1994 Goiânia, Resumos. Goiânia: Associação Brasileira de Milho e Sorgo, 1994. P. 162.
- Omoto, C.; Schmidt, F.B.; Diez-Rodriguez, G.I.; Silva, R.B. Resistência de *Spodoptera frugiperda* a inseticidas no Brasil: situação atual e perspectivas. in: XXIII congresso nacional de milho e sorgo, resumos expandidos, Uberlândia, Associação Brasileira de Milho e Sorgo, 2000.
- 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.
- Plant, R.E. Site-specific management: the application of information technology to crop production. *Computers and Electronics in Agriculture*, Oxford n. 30 p. 9-29, 2001.
- 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. (ed.). *Agricultura de Precisão*. Viçosa: UFV, 2000. P. 1-41.
- Sadjadi, F. Applications of image understanding technology in precision agriculture: weed classification, and row guidance. *Precision Agriculture – Proceedings of the 3rd International Conference, ASA/CSSA/SSSA, Madison*, p. 779-784, 1996.
- Stewart, B.L.& Tian, L.F. Real-time machine vision weed-sensing. *ASAE paper 98 - 3033*, ASAE, 1998. CD Rom.
- Thomas, A.D.H.; Rodd, M.G.; Holt, J.D.; Neill, C.J. Real-time industrial visual inspection: a review. *Real Time Imaging*, London, n.1, p. 139-158, 1995.
- Viana, P.A.; Costa, E.F. Eficiência de inseticidas misturados em óleo vegetal aplicados via irrigação por aspersão para o controle da lagarta do cartucho *Spodoptera frugiperda* em milho. In: MELO, M.A.R. (ed.) *Resumos do XX Congresso Nacional de Milho e Sorgo* Goiânia: Associação Brasileira de Milho e Sorgo, 1994. P. 138.
- Viana, P.A. Manejo de pragas na cultura do milho. in: XXIII congresso nacional de milho e sorgo, resumos expandidos, Uberlândia, Associação Brasileira de Milho e Sorgo, 2000.
- Weisz, R.; Fleischer, S.; Smilowitz, Z. Site-specific integrate pest management for high-value crops: impact on potato pest management. *Journal of Economic Entomology*, Lanham n.89 v.2, p. 501-509, 1996.
- Yang, X; Beyenal, H.; Gary H.; Lewandowski, Z. Evaluation of biofilm image thresholding methods. *Wat. Res.* Vol. 35, p 1149-1158, 2001.

EFEITO DA ILUMINAÇÃO SOBRE A SEGMENTAÇÃO DE IMAGENS DE PLANTAS DE MILHO ATACADAS PELA LAGARTA DO CARTUCHO (*Spodoptera frugiperda*)

RESUMO

A intensidade luminosa é um fator que influencia, diretamente, os valores numéricos dos pixels em uma imagem digital, pois, estes valores representam a energia refletida pelos objetos, que incide no sensor da câmera. O uso de sistemas de visão artificial na área agrícola é dificultado por uma série de fatores inerentes ao meio de trabalho dos equipamentos, sendo um dos mais importantes a grande variação de iluminação, em intensidade e cor, em função da hora do dia e da época do ano. Neste trabalho, foram utilizadas imagens de plantas atacadas e não atacadas pela lagarta do cartucho, em três intensidades luminosas e em três estádios de desenvolvimento, processadas com o índice do excesso de verde normalizado. Os valores do limiar manual, para segmentação das folhas, foram analisados a fim de verificar a influência desses fatores e a eficácia do índice sobre a redução do efeito da variação da intensidade luminosa. Os resultados mostraram que os limiares diferiram para as imagens obtidas, em intensidades luminosas e em estádios culturais diferentes. Estes resultados indicam que a utilização desse índice, isoladamente, não é suficiente para eliminar os efeitos da iluminação e da idade das plantas, dificultando a utilização de um limiar constante para segmentação das folhas do fundo.

Palavras-chave: processamento de imagens, intensidade luminosa, visão artificial, agricultura de precisão.

LIGHT INTENSITY EFFECTS ON IMAGE SEGMENTATION OF DAMAGED CORN PLANTS BY FALL ARMYWORM (*Spodoptera frugiperda*)

ABSTRACT

The light intensity is a factor that directly affects the digital image pixel values, since these values represent the captured camera sensor energy reflected by the objects. The difficulty of using machine vision systems in agricultural area is mainly because of lighting variation, in color and intensity, during the day and the year. In this work, images of damaged

and not damaged plants by the fall armyworm were taken in three light intensities and in three stages, processed with the normalized excess green index. The values of manual thresholds to segment the leaves from the background were compared for verifying these factor influence and the used index efficacy to reduce light intensity variation. The thresholds differed for the images obtained in different light intensities and in different stages. These results indicated that the used index was not enough for eliminating light variation effects, thus the use of a constant threshold could not be efficient.

Key words : image processing, light intensity, machine vision, precision agriculture.

INTRODUÇÃO

O princípio básico da agricultura de precisão é o manejo localizado das áreas agrícolas segundo sua variabilidade, monitorando as condições do solo e da cultura para aplicação dos insumos na dosagem adequada e no local específico. Seu objetivo primordial consiste em maximizar a lucratividade do empreendimento, enquanto outros aspectos importantes podem ser contemplados, tais como o uso mais eficiente dos recursos disponíveis e a redução da contaminação ambiental.

Diversos trabalhos vêm sendo desenvolvidos para viabilizar o emprego das técnicas de agricultura de precisão, utilizando sistemas baseados em mapas ou sensores em tempo real. Em quaisquer dos sistemas, existe demanda para o desenvolvimento de sensores capazes de determinar as propriedades da cultura e, ou do solo, para ajuste da dosagem dos produtos. Normalmente, a obtenção de dados sobre a cultura, tais como o vigor e a presença de doenças, exigem a utilização de amostragens e análises laboratoriais ou mesmo inspeção visual por um especialista. Para implementação das práticas de agricultura de precisão, devido ao custo elevado desses métodos, há a necessidade de desenvolvimento de sistemas mais viáveis, economicamente, para coleta de dados (Stafford 2000).

A lagarta do cartucho é considerada como a principal praga na cultura do milho, no Brasil, apresentando o grau de danos variável de acordo com a época de semeadura, clima, estado nutricional da lavoura e estágio fenológico da planta (Fancelli & Dourado Neto, 2000). Oliveira (1987) observou, em parcelas de milho com solo corrigido, perdas de 42% em relação às parcelas não atacadas. O insucesso do controle desta praga, no Brasil, tem sido creditado à má regulamentação de equipamentos de aplicação, escolha incorreta de produtos e condução inadequada da cultura, o que tem aumentado o número médio de aplicações de inseticidas sem, no entanto, atingir o controle eficaz (Cruz, 1995).

A lagarta do cartucho vem sendo controlada, aplicando-se inseticidas na área total da lavoura por meio de pulverizador costal ou tratorizado (Carvalho, 1987), tratamento de sementes (Oliveira & Silva, 1994) e via água de irrigação (Viana & Costa, 1994). Embora sejam encontrados poucos trabalhos, na literatura, sobre o controle localizado de pragas, a baixa mobilidade da lagarta do cartucho na cultura do milho representa um ponto extremamente favorável à utilização deste tipo de controle.

O aumento da capacidade dos sistemas computacionais, a redução de custos e a dimensão dos equipamentos eletrônicos contribuem para o desenvolvimento de sensores para controle de máquinas em tempo real. Dentre as técnicas estudadas, os sistemas de visão artificial destacam-se, especialmente na realização de tarefas de classificação normalmente desempenhadas por seres humanos. As principais características destes sistemas são a reprodutibilidade e a capacidade de executar medições mais acuradas e consistentes do que aquelas feitas pelo homem, além de medir, objetivamente, a cor e morfologia de objetos (Batchelor, citado por Jayas et al., 2000). Estas técnicas têm sido utilizadas em diversas aplicações agrícolas, fornecendo informações sobre as características e cobertura do solo, condições da cultura, identificação de espécies de plantas, densidade populacional e altura de plantas (Hemming & Rath, 2001). Além disso, têm sido utilizadas no reconhecimento de partes de plantas (Simonton & Pease, 1993), na classificação de segmentos de cultura de tecidos vegetais (Alchanatis et al., 1993), na identificação de danos em sementes (Luo et al. 1999), na identificação de defeitos em frutas (Leemans et al., 1999), dentre outras aplicações.

A aquisição das imagens para utilização em sistemas de visão artificial pode ser realizada, utilizando-se câmeras analógicas ou digitais, sendo necessárias placas específicas para interface com o computador, de acordo com o tipo de câmera.

A intensidade luminosa é um fator que influencia, diretamente, os valores numéricos dos pixels em uma imagem digital, pois, esses valores representam a energia refletida pelos objetos, que incide no sensor da câmera. Steward & Tian (1998), ao desenvolverem um sistema de visão artificial para identificação de plantas daninhas em tempo real, sob iluminação natural, afirmaram que o desafio de se trabalhar no campo é muito maior do que em condições de iluminação controlada. Além da variação nos níveis de iluminação, as sombras provocadas pela incidência direta de luz solar ocasionam diferenças de intensidade dentro de uma mesma imagem. Outro fator importante é a variação na temperatura de cor da luz durante o dia, provocando alterações nas cores dos objetos.

A importância da iluminação para sistemas de visão artificial foi demonstrada em diversos trabalhos. Paulsen & McClure (1986) compararam métodos de iluminação, em

amostras de produtos agrícolas, utilizando diversos filtros e lentes para definir a combinação mais adequada à utilização em sistemas de visão artificial. Thomas et al. (1995), em revisão sobre a aplicação de sistemas de visão artificial em indústrias, afirmam que a iluminação desempenha um papel fundamental na simplificação de um sistema de inspeção. Os autores recomendam o desenvolvimento de um bom sistema de iluminação, pois, o desenvolvimento de algoritmos para resolver os problemas causados nas imagens por um sistema de iluminação deficiente é mais dispendioso.

Lukina et al. (1999) utilizaram o processamento de imagens coloridas para estimar a cobertura do solo e biomassa, na cultura do trigo, e sua relação com o índice de vegetação da diferença normalizada de verde e vermelho (NDVI), determinado a partir da medição da reflectância do dossel de acordo com a equação

$$NDVI = \frac{IV - Vm}{IV + Vm} \quad (1)$$

em que

NDVI - índice da diferença normalizada de verde e vermelho;

IV - reflectância na faixa do infravermelho próximo; e

Vm - reflectância na faixa do vermelho.

A cobertura do solo, determinada por esse método, apresentou uma alta correlação com os índices de NDVI. No entanto, observou-se que esse método foi altamente influenciado pela iluminação, não sendo possível utilizar o mesmo método de processamento para todas as imagens.

El-Faki et al. (2000), com o objetivo de estudar os fatores que afetam a detecção de plantas daninhas por meio de imagens coloridas, obtiveram imagens de padrões de cores vermelho, verde e azul em nove intensidades de iluminação. Os resultados demonstraram que a utilização de índices relativos de cor permitiu a discriminação dos padrões, nas diversas intensidades de iluminação, e que a utilização desses índices aumentou significativamente a eficácia de classificadores baseados em cor, quando a iluminação não foi completamente controlada.

Um dos passos fundamentais no processamento de imagens digitais em sistemas de visão artificial é a segmentação, que consiste em dividir a imagem em suas partes constituintes. Uma das técnicas mais utilizadas é a limiarização, especialmente quando os valores dos pixels apresentam uma distribuição bimodal e o objetivo é agrupá-los em duas

classes. Nesta técnica, um valor é estabelecido (limiar) e os pixels que apresentam valor superior ao limiar são agrupados em uma classe e abaixo do mesmo são agrupados em outra.

Em imagens obtidas de um mesmo objeto, sob diferentes intensidades de iluminação, ou em uma imagem de um objeto com parte sombreada, os pixels apresentam valores distintos. Esta é a realidade encontrada nos sistemas de visão artificial utilizados em condições de iluminação natural, em que ocorre uma grande variação na intensidade luminosa ao longo do dia. Nessas condições, o limiar utilizado para agrupar os pixels pertencentes a um mesmo objeto deve ser dinâmico, ou o sistema deve utilizar técnicas capazes de minimizar os efeitos da variação de intensidade luminosa, permitindo trabalhar com um valor definido previamente.

A normalização é uma técnica, que utiliza os valores originais dos pixels em mais de uma banda da imagem para gerar uma nova imagem, na qual os efeitos da variação de iluminação são reduzidos e a variância nos valores dos pixels é baixa para regiões coloridas da imagem, facilitando a segmentação (Andreadis & Tsalides, 1997). Diversos índices são amplamente utilizados na área de sensoriamento remoto, no intuito de reduzir a diferença de brilho, em materiais idênticos, causados por diferenças na topografia do terreno, sombras ou mudanças sazonais no ângulo e intensidade da iluminação solar. Além disso, permite realçar características de interesse e reduzir o número de bandas necessárias à interpretação, concentrando a informação (Jensen, 1996).

Woebbecke et al. (1995) testaram diversos índices de cor para distinção de plantas do solo e resíduos em condições de iluminação natural em imagens sombreadas e não sombreadas. Os melhores resultados foram obtidos com os índices de matiz modificado e o excesso de verde; no entanto, o matiz modificado mostrou-se mais exigente computacionalmente. Meyer et al. (1998) também utilizaram o índice de excesso de verde normalizado, associado a técnicas de avaliação de textura, para identificar quatro espécies de plantas daninhas, sendo duas de folhas estreitas e duas de folhas largas, classificando solo e plantas daninhas. O método utilizado foi eficiente para classificar o solo e as plantas daninhas, com acurácia acima de 99%.

Devido à importância da lagarta do cartucho como praga na cultura do milho, no Brasil, o desenvolvimento de um algoritmo para identificação de plantas atacadas por esta praga, utilizando-se imagens digitais, poderá viabilizar seu controle localizado. No entanto, para isto, são necessárias informações básicas sobre os fatores que podem influenciar a escolha do valor de limiar para segmentação das plantas e do fundo. A maioria dos trabalhos encontrados na literatura avalia a eficácia da utilização de índices para o processamento de

imagens de forma descritiva. Portanto, o objetivo deste trabalho foi avaliar o índice do excesso de verde normalizado para processamento de imagens de plantas de milho bem como avaliar, estatisticamente, os efeitos da intensidade luminosa, da presença ou não de injúrias provocadas pela lagarta do cartucho e do estágio de desenvolvimento das plantas sobre o valor de limiar mais adequado.

MATERIAL E MÉTODOS

Instalou-se um experimento em delineamento inteiramente casualizado com cinco repetições no esquema de parcelas subdivididas, em que as parcelas principais eram plantas atacadas e não atacadas, e as parcelas secundárias três intensidades luminosas. Adicionalmente, medidas repetidas foram tomadas em cada unidade experimental, uma vez que foram obtidas imagens de cada planta em três estádios distintos, perfazendo, assim, um total de 90 imagens.

O experimento foi conduzido nas dependências da Embrapa Milho e Sorgo, em Sete Lagoas, MG. Três sementes do híbrido triplo HT971011 foram semeadas no dia 26/06/2001, em vasos de 15 litros, em solo peneirado e adubado com 3,00 kg de adubo formulado NPK 4-14-8 por tonelada de solo, mantidos em casa-de-vegetação. As plantas emergiram no dia 03/07/2001 e, após uma semana, foram desbastadas, deixando-se somente uma planta por vaso. Quinze dias após a emergência, foram escolhidos, aleatoriamente, quinze vasos e cada planta foi infestada com 10 lagartas de *Spodoptera frugiperda* eclodidas no dia anterior.

As imagens foram obtidas aos 17, 20 e 23 dias após a emergência (DAE), que correspondiam a 2, 5 e 8 dias após a infestação pela lagarta do cartucho (DAI), com a câmera posicionada um metro acima das folhas mais altas das plantas. Utilizou-se uma câmera digital DUNCANTECH, modelo MS3100, conectada a um computador Pentium 75 por meio de uma placa de aquisição de vídeo fabricada por National Instruments, modelo PCI 1424. As imagens coloridas RGB foram salvas com 1392 (H) e 1039 (V) pixels no formato TIF (“tagged image file format”). A câmera era equipada com 3 CCD (“charge-coupled device”), os quais permitiam o controle do ganho e do tempo de exposição em cada sensor individualmente. 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 permitia o controle manual da abertura da íris, em que o “f-stop” foi definido em 3,5. A Tabela 1 apresenta o ganho e o tempo 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) para um “f-stop” de 3,5

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

Para obtenção das imagens em condições de iluminação controlada, construiu-se uma estrutura metálica com dimensões 1,50m por 1,50m e 2,00m de altura, 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 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. Foram obtidas imagens em três intensidades de iluminação, mantendo-se os quatro refletores acesos e acendendo-se as demais lâmpadas sucessivamente, duas a duas.

As imagens foram processadas, utilizando-se o programa computacional MATLAB versão 6 com o pacote de ferramentas para processamento de imagens. As imagens originais foram processadas com o índice do excesso de verde normalizado, de acordo com a equação

$$Evd = \frac{2 \cdot Vd - Vm - Az}{Vm + Vd + Az} \quad (2)$$

em que

Evd - excesso de verde normalizado;

Vd - valor do pixel na banda verde;

Vm - valor do pixel na banda vermelha; e

Az - valor do pixel na banda azul.

Tendo em vista que as imagens processadas apresentavam valores entre -1 e 2 procedeu-se a uma transformação linear nos valores dos pixels, criando-se imagens em 256 tons de cinza, de acordo com a equação

$$Evd_t = \frac{Evd_o - Evd_{\min}}{Evd_{\max} - Evd_{\min}} \cdot 255 \quad (3)$$

em que

Evd_t - valor do pixel na imagem transformada;

Evd_o - valor do pixel na imagem processada;

Evd_{min} - valor máximo de pixel na imagem processada ; e

Evd_{max} - valor mínimo de pixel na imagem processada.

As imagens coloridas originais apresentavam, em suas bordas, pixels com valores nulos, provenientes possivelmente da aquisição das imagens pela placa. Para não influenciarem os resultados dos testes foram eliminadas as 10 primeiras e as 10 últimas colunas de pixels das imagens, assim como as 10 primeiras e as 10 últimas linhas, reduzindo a dimensão das imagens processadas para 1372 (H) por 1019 (V) pixels.

Uma rotina foi desenvolvida no programa computacional MATLAB, para que cada um de cinco operadores pudesse obter manualmente, por tentativa, um valor de limiar que segmentasse adequadamente as classes folha e fundo nas imagens normalizadas. Essa rotina apresentava, inicialmente, a imagem colorida original e uma imagem binária criada, utilizando-se um limiar baixo. O operador poderia aumentar ou diminuir o limiar, sem ter acesso ao valor, para não influenciar a limiarização das imagens subsequentes. A cada alteração do limiar pelo operador, o programa apresentava a nova imagem binária acompanhada da imagem original. No momento em que o operador considerava a imagem binária satisfatória, o programa salvava, em um arquivo, o nome da imagem e o valor do limiar. Ao final, para cada imagem, uma média aritmética foi calculada, usando-se os limiares obtidos pelos cinco operadores.

Esses limiares médios, assim obtidos, foram utilizados para estudar os efeitos da intensidade luminosa, da presença ou não de injúrias provocadas pela lagarta do cartucho e do estágio de desenvolvimento das plantas, bem como as interações simples entre esses efeitos. O procedimento PROC MIXED do programa SAS (Littel et al., 1996) foi utilizado, para realizar uma análise de variância e, assim, verificar se os efeitos mencionados acima foram significativos ao nível de 1% de probabilidade. Segundo o teste de Kolmogorov-Smirnov, os erros associados ao modelo estatístico adotado para a análise dos valores dos limiares manuais apresentaram uma distribuição normal.

RESULTADOS E DISCUSSÃO

As Figuras 1-a e 1-c ilustram as imagens originais de uma planta de milho com injúrias provocadas pela lagarta do cartucho, obtidas 17 DAE – 2 DAI e 23 DAE - 08 DAI, respectivamente. As Figuras 1b e 1d ilustram as imagens processadas com o índice do excesso de verde normalizado, a partir das imagens 1a e 1c, respectivamente.

Nas imagens processadas, os pixels representando folhas apresentaram-se mais claros do que todo o restante da imagem, inclusive as bordas do vaso que apareceram em branco na imagem original. Esse processamento facilita a segmentação das plantas em imagens obtidas no campo, onde a palha e outros resíduos vão aparecer como porções claras na imagem original.




Figura 1. Imagens originais e processadas com o índice do excesso de verde normalizado de uma planta atacada pela lagarta do cartucho, aos 17 DAE – 2 DAI (a e b) e aos 23 DAE – 8 DAI. (c e d).

A Figura 2 ilustra a geração das imagens binárias, a partir das imagens processadas. As imagens à esquerda (planta atacada) e à direita (planta não atacada) foram obtidas nas intensidades de iluminação um (mais baixa) e três (mais alta), respectivamente. As Figuras 2a, 2b e 2c ilustram as imagens processadas, seus histogramas e as imagens binárias, respectivamente. Na Figura 2b também estão indicados os limiares considerados adequados a segmentação das folhas do fundo. Embora as imagens originais tenham sido obtidas em condições diferentes de iluminação, os histogramas das imagens processadas apresentaram-se semelhantes, com as duas classes agrupadas em torno dos mesmos valores de tons de cinza, com um vale acentuado separando as duas classes, o que poderia facilitar a segmentação das folhas.




Figura 2 – Imagens em tons de cinza de uma planta atacada (à esquerda) e uma não atacada (à direita) obtidas sob duas condições de iluminação (a), histogramas das imagens em tons de cinza (b) e as imagens binárias geradas a partir das imagens em tons de cinza(c).

A Tabela 2 apresenta a saída parcial do programa SAS para o teste F dos valores dos limiares médios. O procedimento PROC MIXED do programa SAS não produz uma saída usual e completa da análise de variância, razão pela qual apenas os graus de liberdade e valores de F são mostrados para cada fonte de variação. Verifica-se que os fatores ataque, iluminação e estágio foram significativos ao nível de 1% de probabilidade pelo teste F, assim como a interação estágio-ataque. As interações ataque-iluminação e estágio-iluminação não mostraram-se significativas ao nível de 1% de probabilidade pelo teste F. Estes resultados concordam com os obtidos por El-Faki et al. (2000), em que a utilização de índices de cor

permitiu a diferenciação de padrões de cor, porém o valor dos índices não foi o mesmo para todas as condições de iluminação.

Tabela 2. Resultados do teste F para os valores da média dos limiares manuais

Fator de Variação	Grau de liberdade	F	
Ataque (A)	1	15,43	**
Iluminação (I)	2	17,90	**
A x I	2	0,40	ns
Estádio (E)	2	71,44	**
E x A	2	31,40	**
E x I	4	2,03	ns

** Significativo ao nível de 1% de probabilidade.

ns, não-significativo

O teste F para iluminação mostrou que o processamento das imagens, utilizando-se o índice do excesso de verde normalizado, não foi suficiente para eliminar os efeitos da variação de intensidade luminosa. Além disso, com a utilização desse índice, o limiar deve ser ajustado de acordo com o estágio de desenvolvimento das plantas, uma vez que o teste F foi significativo para estágio de desenvolvimento. Acredita-se que a diferença no valor do limiar, para os diferentes estágios, possivelmente, é devida à proporção de pixels representando folhas nas imagens, com maior cobertura do solo à medida que as plantas desenvolvem. Além disto, outro fator que pode ter influenciado os valores dos limiares, nos diferentes estágios, é o porte das plantas. Durante a coleta dos dados, à medida que as plantas desenvolviam, a altura do suporte para os vasos era reduzida, visando manter a distância entre a câmera e as folhas mais altas. No entanto, o sistema de iluminação permaneceu fixo, acima da câmera. As plantas mais desenvolvidas apresentavam um maior número de folhas em camadas e, embora as folhas do topo estivessem sendo iluminadas com a mesma intensidade, em todas as imagens, as folhas das camadas inferiores estavam sendo iluminadas mais fracamente. Uma vez que a iluminação mostrou-se significativa, essas folhas inferiores podem ter influenciado o valor do limiar das imagens como um todo, especialmente nas plantas mais desenvolvidas.

O fato de o ataque influenciar significativamente o limiar não era esperado, uma vez que, em relação ao número de pixels da imagem, o número de pixels representando as porções atacadas da folha foi pequeno, especialmente no início do ataque. No entanto, nas plantas mais desenvolvidas, em que as injúrias provocadas pela lagarta eram maiores, essa proporção foi, provavelmente, diferente para plantas atacadas e não atacadas, o que pode explicar a

interação significativa estádio-ataque. Uma vez que essa interação foi significativa, a interação foi desdobrada, realizando-se o teste F ao nível de 1% de probabilidade, para os valores dos limiares de plantas atacadas e não atacadas dentro dos níveis do fator estádio de desenvolvimento (Tabela 3).

Tabela 3. Resultados do teste F para a interação entre os fatores estádio e ataque

Efeito	estádio	Grau de liberdade	F	
Estádio*ataque	0720	1	1,27	ns
Estádio*ataque	0723	1	2,08	ns
Estádio*ataque	0726	1	57,53	**

** Significativo ao nível de 1% de probabilidade.

ns, não-significativo

Verifica-se que, para os dois primeiros estádios, com as plantas mais novas e o ataque mais recente, o valor de F não foi significativo ao nível de 1% de probabilidade, ao passo que para o último estádio, com as plantas mais desenvolvidas e o ataque mais acentuado, com injúrias maiores, o valor de F foi significativo ao nível de 1% de probabilidade. Estes resultados, juntamente com o resultado significativo do teste F para o estádio de desenvolvimento das plantas, reforçam a suspeita que a diferença do valor do limiar foi causado pela percentagem de pixels representando folhas.

Outra possibilidade a ser considerada é que os operadores tenham influenciado, inconscientemente, os valores dos limiares para as plantas atacadas e não atacadas, utilizando a segmentação das injúrias nas plantas atacadas, como critério, para definir se a imagem binária era adequada ou não.

De acordo com estes resultados, verifica-se que será difícil a utilização de um limiar fixo para a segmentação de plantas, utilizando-se o índice do excesso de verde normalizado em sistemas de visão artificial com iluminação natural. Resultados semelhantes são encontrados na literatura (Steward & Tian, 1998; Tian & Slaughter, 1998). Acredita-se que para que se possa utilizar limiares fixos será necessário um sistema adicional para reduzir, ainda mais, os efeitos da variação de intensidade luminosa e porte das plantas. No entanto, para que o sistema possa determinar um limiar específico para cada situação encontrada no campo, deverá ser utilizado um método automático de limiarização. Outra possibilidade que deve ser avaliada é a utilização de um limiar único, associado a um método de classificação robusto o suficiente, para conseguir realizar uma classificação satisfatória das plantas como atacadas e não atacadas, mesmo que as imagens não tenham sido binarizadas, utilizando-se o

limiar mais adequado para cada situação. Battle et al. (2000), em revisão sobre estratégias para reconhecimento de objetos em imagens coloridas obtidas em ambientes externos, consideraram que este tipo de cena é especialmente complexo, e que os resultados obtidos por sistemas de visão artificial nessas condições devem ser melhorados, pois, os problemas só estão solucionados para cenas simples.

CONCLUSÕES

Neste trabalho, foram avaliados os efeitos da variação de intensidade luminosa, estágio de desenvolvimento e presença de injúrias provocadas pela lagarta do cartucho, *Spodoptera frugiperda*, sobre o valor do limiar adequado para segmentação das folhas, nas imagens de plantas de milho processadas com o índice do excesso de verde normalizado.

Verificou-se que os fatores ataque, iluminação e estágio de desenvolvimento foram significativos ao nível de 1% de probabilidade pelo teste F, assim como a interação estágio-ataque. O desdobramento desta interação mostrou que os limiares para plantas atacadas e não atacadas foram diferentes, somente, para as plantas mais desenvolvidas e com injúrias mais acentuadas, possivelmente devido à proporção entre pixels representando folhas e fundo.

As interações ataque-iluminação e estágio-iluminação não mostraram-se significativas no valor do limiar, ao nível de 1% de probabilidade pelo teste F.

AGRADECIMENTOS

Aos pesquisadores, técnicos e demais funcionários da Embrapa Milho e Sorgo, em Sete Lagoas, MG, por viabilizarem o desenvolvimento desta pesquisa. À Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), pelo financiamento concedido ao primeiro autor durante o curso de mestrado.

LITERATURA CITADA

- Alchanatis, V.; Peleg, K.; Ziv, M. Classification of tissue culture segments by colour machine vision. *Journal of Agricultural Engineering Research*, London n.55, 299-311, 1993.
- Andreadis, I. & Tsalides, P. Analog computation of image chromaticity *Real-Time Imaging*, London, n.3, p.1 – 6, 1997.
- Battle, J.; Casals, A.; Freixenet, J.; Martí, J. A review on strategies for recognizing natural objects in colour images of outdoor scenes. *Image and Vision Computing*, Amsterdam, n.18 p. 515–530, 2000.

- Carvalho, R.P.L. Pragas do milho. In: Paterniani, E.; Viégas, G.P. (ed.) Melhoria e Produção de Milho. 2 ed. Campinas: Fundação Cargill, 1987. p. 637 – 712 .
- Cruz, I. A lagarta do cartucho na cultura do milho. Sete Lagoas: EMBRAPA-CNPMS, 42P. (EMBRAPA-CNPMS. Circular Técnica, 21). 1995.
- El-Faki, M.S.; Zhang, N.; Peterson, D.E. Factors affecting color-based weed detection. Transactions of the ASAE. St. Joseph, v.43 n.4, p.1001 -1009, 2000.
- Fancelli, A.L. & Dourado Neto, D. Produção de milho. 1 ed. Guaíba: Livraria e Editora Agropecuária, 2000, 360p.
- Hemming, J & Rath, T. Computer-vision-based weed identification under field conditions using controlled lighting. Journal of Agricultural Engineering Research, London. n.78 v.3 p. 233-243, 2001.
- Jayas, D.S.; Paliwal, J.; Visen, N.S. Multi-layer neural networks for image analysis of agricultural products. Journal of Agricultural Engineering Research, London v.77 n.2, p.119-128, 2000.
- Jensen, J.R. Introductory digital image processing: a remote sensing perspective. New York: Prentice Hall, 1996, 318p.
- Leemans, V.; Magein, H.; Destain, M.F. Defect segmentation on 'jonagold' apples using colour vision and a bayesian classification method. Computers and Electronics in Agriculture, Oxford, v. 23 p. 43–53, 1999.
- Little, R.C.; Milliken, G.A.; Stroup, W.W.; Wolfinger, R.D. SAS System for Mixed Models, Cary: SAS Institute inc, 1996, 633p.
- Lukina, E.V.; Stone, M.L.; Raun, W.R. Estimating vegetation coverage in wheat using digital images. Journal of Plant Nutrition, New York n. 22 p. 341-350, 1999.
- Luo, X.; Jayas, D.S.; Symons, S.J. Identification of damaged kernels in wheat using a colour machine vision system. Journal of Cereal Science, London, 30 p. 49–59, 1999.
- Meyer, G.E.; Mehta, T.; Kocher, M.F.; Mortensen, D.A.; Samal, A. Textural imaging and discriminant analysis for distinguishing weeds for spot spraying. Transactions of the ASAE. St. Joseph, v.41 n.4, p.1189 -1197, 1998.
- Oliveira, J.P. & Silva, A.L. Controle químico da lagarta do cartucho (*Spodoptera frugiperda*) em milho, com novo regulador de crescimento. In: XX Congresso Nacional de Milho e Sorgo, 1994 Goiânia, Resumos. Goiânia: Associação Brasileira de Milho e Sorgo, 1994. P. 162.
- Oliveira, L.J. Biologia, nutrição quantitativa e danos causados por *Spodoptera frugiperda* (J.E. Smith, 1797) (Lepidoptera: noctuidae) em milho cultivado em solo corrigido para três

- níveis de alumínio. Piracicaba, 1987. 125p. Dissertação (mestrado em Ciências Biológicas) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo.
- Paulsen, M.R. & McClure, W.F. Illumination for computer vision systems Transactions of the ASAE. St. Joseph, v.29 n.5, p.1398 -1404, 1986.
- Simonton, W. & Pease, J. Orientation independent machine vision classification of plant parts. Journal of Agricultural Engineering Research, London n. 54, 231-243, 1993.
- Stafford, J.V. Implementing precision agriculture in the 21st century. Journal of Agricultural Engineering Research, London.n.76, 267-275, 2000.
- Stewart, B.L. & Tian, L.F. Real-time machine vision weed-sensing. ASAE paper 98-3033, ASAE, 1998. CD Rom.
- Thomas, A.D.H.; Rodd, M.G.; Holt, J.D.; Neill, C.J. Real-time industrial visual inspection: a review. Real-Time Imaging, London n.1, p. 139-158, 1995.
- Tian, L.F. & Slaughter D.C. Environmentally adaptive segmentation algorithm for outdoor image segmentation Computers and Electronics in Agriculture, Oxford n. 21 p. 153 –168, 1998.
- Viana, P.A. & Costa, E.F. Eficiência de inseticidas misturados em óleo vegetal aplicados via irrigação por aspersão para o controle da lagarta do cartucho *Spodoptera Frugiperda* em milho. In: In: XX Congresso Nacional de Milho e Sorgo, 1994 Goiânia, Resumos. Goiânia: Associação Brasileira de Milho e Sorgo, 1994. p. 138.
- Woebbecke, D.M.; Meyer, G.E.; Von Barga, K.; Mortensen, D.A. Color indices for weed identification under various soil, residue, and lighting conditions. Transactions of the ASAE. St. Joseph, v.38 n.1, p.259 -269, 1995.

AVALIAÇÃO DE MÉTODOS AUTOMÁTICOS DE LIMIA RIZAÇÃO PARA IMAGENS DE PLANTAS DE MILHO ATACADAS PELA LAGARTA DO CARTUCHO (*Spodoptera frugiperda*)

RESUMO

Um dos passos fundamentais no processamento de imagens para um sistema de visão artificial é a segmentação dos objetos de interesse na cena, e um dos métodos mais utilizados é a limiarização, especialmente quando o objetivo é agrupar os pixels em duas classes. Neste método, o valor do limiar determina o número de pixels atribuídos a cada classe, além de influenciar a dimensão e a forma dos objetos nas imagens segmentadas. A utilização de métodos automáticos para definição do limiar não só evitaria a influência de operadores, mas também tornaria mais rápida a escolha dos limiares no campo, onde a variação da iluminação influencia os valores dos pixels. O objetivo deste trabalho foi implementar e avaliar dois métodos automáticos de limiarização para identificação de plantas de milho atacadas pela lagarta do cartucho. Foram utilizadas imagens de plantas atacadas e não atacadas, em três épocas, correspondendo a diferentes dias após a infestação. As plantas foram reunidas em três grupos de 10, sendo as imagens de cada grupo obtidas em uma intensidade luminosa diferente. As imagens processadas com o índice do excesso de verde normalizado foram limiarizadas, automaticamente, e comparadas com a limiarização manual das mesmas imagens. Os resultados obtidos pelos dois métodos automáticos de limiarização foram satisfatórios, apresentando uma média acima de 99% de exatidão global, evidenciando-se, portanto, que ambos os métodos têm potencial para ser utilizados em um sistema de identificação de plantas de milho atacadas pela lagarta do cartucho

Palavras-chave: processamento de imagens, visão artificial, agricultura de precisão.

AUTOMATIC THRESHOLD EVALUATION ON FALL ARMYWORM (*Spodoptera frugiperda*) DAMAGED CORN PLANT IMAGES

ABSTRACT

A fundamental step in image processing for machine vision is the scene segmentation, and one of the most used methods is threshold, specially when desires to cluster the pixels in

two classes. The image threshold affects the number of pixels in each class and the object shapes. An automatic threshold not only could avoid operator's influence but also could speed up the threshold value definition in the field, where the light variation influences the pixels values. In this work, two automatic threshold methods were evaluated for using in a machine vision system that identifies damaged corn plants by the fall armyworm. The used images were of damaged and not damaged corn plants in three stages. Three groups of 10 plants were created to take the images in three different light intensities. The images processed with the excess green index were thresholded with the automatic methods and compared to the manual threshold. The results of both automatic methods were good, with average accuracy higher than 99%, showing potential to be used by a system for identifying the damaged corn plants.

Key words : Image processing, machine vision, precision farming

INTRODUÇÃO

A necessidade de aumento da produção agrícola em virtude do crescimento da população promoveu o desenvolvimento da mecanização, o que permitiu o cultivo de grandes áreas. As parcelas foram incorporadas em talhões devido à impossibilidade de maneja-las de acordo com suas características particulares com manejo e aplicação de insumos definidos pela média. A partir da disponibilidade de técnicas de localização precisas com custo acessível, aliada ao desenvolvimento de sensores e sistemas eletrônicos aplicáveis a máquinas agrícolas, descortinou-se a possibilidade de manejo em sítio específico dessas áreas. Esse manejo, de acordo com as exigências locais, é o que vem sendo denominado como agricultura de precisão (AP), pelos técnicos.

A agricultura de precisão busca o uso de técnicas que permitam a produção de fibras e alimentos de forma competitiva. Seu principal objetivo é evidenciar a variabilidade espacial e temporal de atributos do sistema de produção e manter, ou aumentar, a lucratividade do empreendimento, ao mesmo tempo em que reduz a contaminação ambiental causada pelo uso de defensivos e fertilizantes, quando comparada com o tratamento uniforme dos talhões da agricultura tradicional. A aplicação diferenciada de insumos em AP pode ser realizada, com base em mapas de prescrição, ou utilizando-se sensores em tempo real (Queiroz et al., 2000). Os mapas de prescrição são elaborados, previamente à aplicação, a partir de dados de produtividade, fertilidade de solos, infestação da lavoura por pragas, doenças ou plantas daninhas, dentre outros. Os sensores são capazes de determinar as características do sistema

produtivo (solo e cultura) em tempo real, para ajustar a dose de aplicação de insumos agrícolas.

A principal praga na cultura do milho, no Brasil, é a lagarta do cartucho (*Spodoptera frugiperda*) (Fancelli & Dourado Neto 2000). Perdas de até 42% da produção em parcelas de milho atacadas por esse inseto, em relação a parcelas não atacadas, já foram detectadas (Oliveira, 1987). A lagarta do cartucho vem sendo controlada por meio da aplicação de inseticidas na área total da lavoura, quando a população atinge o nível de ação, ou seja, o dano provocado pela praga justifica, economicamente, a utilização de medidas de controle. Para controle, utilizam-se principalmente métodos convencionais, por meio de pulverizador costal ou tratorizado (Carvalho, 1987), tratamento de sementes (Oliveira & Silva, 1994) e via água de irrigação (Viana & Costa, 1994). O nível de infestação é estimado, contando-se as plantas com injúrias provocadas pela lagarta, em amostragem realizada ao acaso, na lavoura, por pessoal treinado. Embora poucos trabalhos tenham sido publicados, visando ao controle localizado de pragas em culturas, a lagarta do cartucho apresenta um grande potencial para este tipo de controle devido à sua baixa mobilidade na cultura.

Um dos métodos estudados para viabilizar a coleta de dados para AP é a utilização de sistemas de visão artificial (SVA). As principais características destes sistemas são a reprodutibilidade, a possibilidade de operar em praticamente todo o espectro de radiações eletromagnéticas e a capacidade de medir objetivamente a cor de objetos (Marques Filho & Vieira Neto, 1999). Estes sistemas constituem-se, basicamente, de uma câmera conectada a um computador por meio de uma placa de aquisição de vídeo e de programas computacionais específicos de processamento de imagens para extração das informações desejadas. A partir dessas informações o sistema pode gerar um sinal para controle de máquinas, ou armazenar os dados para utilização posterior como, por exemplo, a elaboração de um mapa de prescrição (Pinto et al., 2001). Tais técnicas (SVA) têm sido utilizadas em diversas aplicações agrícolas, fornecendo informações sobre as características e cobertura do solo, condições da cultura, identificação de espécies de plantas, densidade populacional e altura de plantas (Hemming & Rath, 2001). Além disso, têm sido utilizadas para reconhecimento de partes de plantas (Simonton e Pease, 1993), classificação de segmentos de cultura de tecidos vegetais (Alchanatis et al., 1993), identificação de danos em sementes (Luo et al., 1999) e defeitos em frutas (Leemans et al., 1998) dentre outras.

Em um SVA, é muito importante a subdivisão da imagem em suas partes constituintes ou objetos, técnica conhecida como segmentação. Para isto, é utilizada a limiarização, especialmente quando os valores dos pixels apresentam uma distribuição bimodal e o objetivo

é agrupá-los em duas classes, criando-se uma imagem binária. Neste caso, um valor é estabelecido (limiar) e os pixels que apresentam valores inferiores e superiores ao limiar são agrupados em duas classes diferentes. A seguir, são extraídas das imagens binárias as características que serão utilizadas para classificar os objetos presentes. Medições adequadas de objetos, em imagens, requerem o uso de um método de limiarização confiável e acurado, devido à influência no número de pixels atribuídos a cada classe, a dimensão e a forma dos objetos segmentados. Frequentemente, a seleção do método é feita com base em experimentação e avaliação (Yang et al., 1995). O ideal seria a utilização de um método automático, para evitar influência de operadores. Contudo, em muitos casos, as imagens limiarizadas manualmente são utilizadas como uma segmentação de referência para comparação com o resultado do algoritmo (Yang et al., 2001).

A intensidade luminosa é um fator que influencia, diretamente, os valores numéricos dos pixels em uma imagem digital, uma vez que esses valores representam a energia refletida pelos objetos e incidente no sensor da câmera. Este é um dos desafios enfrentados na utilização de SVA para agricultura de precisão, em razão da variação dos níveis de iluminação e das sombras presentes na imagem (Steward & Tian, 1998). Outro fator que dificulta a segmentação da imagem é a variabilidade de cor da luz de acordo com o dia e com a época do ano (Tian & Slaughter, 1998). Battle et al. (2000), em revisão sobre estratégias para reconhecimento de objetos em imagens coloridas obtidas em ambientes externos, afirmaram que os resultados obtidos por SVA, nessas condições, precisam ser melhorados, pois, os problemas só estão solucionados para cenas simples.

Ling & Ruzhitsky (1996) utilizaram um SVA para medição automática da área do dossel de plantas de tomate, objetivando estimar a qualidade de mudas. As imagens foram obtidas em um ambiente com iluminação controlada e segmentadas por dois métodos: Otsu adaptado para trabalhar em condições multimodais, e o método de limiares fixos, obtidos por treinamento com imagens similares. Os métodos automáticos apresentaram erros entre -2 a 6%, quando seus resultados foram comparados com a limiarização manual. Yang et al. (2001) avaliaram cinco métodos de limiarização de imagens microscópicas de biofilmes, visando segmentar o material biológico dos espaços intersticiais. O único método que apresentou resultados satisfatórios foi o iterativo, mostrando potencial para substituir o limiar manual. Tang et al. (2000) utilizaram um algoritmo genético para segmentação de regiões representando plantas em um mosaico de imagens, obtidas em condições diversas, para detecção de plantas daninhas. O resultado do algoritmo foi comparado com uma imagem

segmentada manualmente, mostrando-se promissor para contornar as dificuldades impostas pela variação de iluminação.

A segmentação pode ser facilitada com a normalização, uma técnica muito utilizada para reduzir os efeitos da variação de iluminação e a variância nos valores dos pixels na imagem. Nesta técnica, os valores originais dos pixels, em mais de uma banda da imagem são combinados em índices para gerar uma nova imagem (Andreadis & Tsalides, 1997). Os índices são amplamente utilizados na área de sensoriamento remoto, no intuito de reduzir a diferença de brilho em materiais idênticos, causados por diferenças na topografia do terreno, sombras ou mudanças sazonais no ângulo e intensidade da iluminação solar. Além disso, permite realçar características de interesse e reduzir o número de bandas necessárias à interpretação, concentrando a informação (Jensen, 1996). Woebbecke et al. (1995) testaram diversos índices de cor para distinção de plantas do solo e resíduos, em condições de iluminação natural, em imagens sombreadas e não sombreadas. Os melhores resultados foram obtidos com os índices de matiz modificado e o excesso de verde; no entanto, o primeiro exigiu mais tempo de processamento. Meyer et al. (1998) também utilizaram o índice de excesso de verde normalizado, associado a técnicas de avaliação de textura, para identificar quatro espécies de plantas daninhas, mostrando-se eficiente para classificar o solo e plantas daninhas com acurácia acima de 99%.

O objetivo deste trabalho foi implementar e avaliar dois métodos automáticos de limiarização, iterativo (Yang et al., 2001) e bayesiano (Gonzales & Woods, 1992), utilizando imagens processadas de plantas de milho atacadas e não atacadas pela lagarta do cartucho (*Spodoptera frugiperda*).

MATERIAL E MÉTODOS

Imagens de 15 plantas atacadas e 15 plantas não atacadas pela lagarta do cartucho foram obtidas, em três épocas distintas e em três intensidades de iluminação, em condições de casa-de-vegetação nas dependências da Embrapa Milho e Sorgo, em Sete Lagoas, MG. As plantas foram reunidas em grupos de 10 plantas (5 atacadas e 5 não atacadas) assim como as imagens de cada grupo obtido em uma intensidade de iluminação, perfazendo um total de 30 imagens para cada estádio.

O trabalho foi conduzido utilizando-se 30 vasos de 15 litros com solo peneirado e adubado com adubo formulado NPK 4-14-8 na quantidade de 3,00 kg por tonelada de solo, mantidos em casa-de-vegetação. Em cada vaso foram semeadas três sementes do híbrido triplo HT971011 no dia 26/06/2001. As plantas emergiram no dia 03/07/2001 e, após uma

semana, foram desbastadas para uma planta por vaso. Quinze dias após a emergência, foram escolhidas, aleatoriamente, quinze plantas para infestação com 10 lagartas de *Spodoptera frugiperda* eclodidas no dia anterior.

As plantas foram sorteadas para obtenção das imagens em três intensidades de iluminação, aos 17, 20 e 23 dias após a emergência, correspondendo a 2, 5 e 8 dias após a infestação pela lagarta do cartucho, com a câmera posicionada a um metro acima das folhas mais altas das plantas. Utilizou-se uma câmera digital DUNCANTECH, modelo MS3100, conectada a um microcomputador por meio de uma placa de aquisição de vídeo da National Instruments, modelo PCI 1424. As imagens coloridas RGB foram salvas com dimensões de 1392 (H) e 1039 (V) pixels no formato TIF (“tagged image file format”). A câmera utilizada era equipada com 3 CCD (“charge-coupled device”), os quais permitiam o controle do ganho e do tempo de exposição em cada sensor. Os CCD foram destinados à coleta das bandas do vermelho, do infravermelho próximo e do verde e azul. A lente permitia o controle manual da abertura da íris, em que o “f-stop” foi definido em 3,5. A Tabela 1 apresenta o ganho e o tempo 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) para um “f-stop” de 3,5

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

Para obtenção das imagens em condições de iluminação controlada, construiu-se uma estrutura metálica com dimensões 1,50m por 1,50m e 2,00m de altura, 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. Para obtenção das três intensidades de iluminação, os quatro refletores foram mantidos acesos e as demais lâmpadas foram acesas, sucessivamente, duas a duas.

As imagens foram processadas no Laboratório de Projeto de Máquinas e Visão Artificial do Departamento de Engenharia Agrícola da Universidade Federal de Viçosa. Foi utilizado o programa computacional MATLAB com o pacote de ferramentas para processamento de imagens. As imagens originais foram processadas com o índice do excesso de verde normalizado, de acordo com a equação

$$Evd = \frac{2 \cdot Vd - Vm - Az}{Vm + Vd + Az} \quad (1)$$

em que

Evd - excesso de verde normalizado;

Vd - valor do pixel na banda verde;

Vm - valor do pixel na banda vermelha; e

Az - valor do pixel na banda azul.

Tendo em vista que as imagens processadas apresentavam valores entre -1 e 2 procedeu-se a uma transformação linear nos valores dos pixels, criando-se imagens em 256 tons de cinza, de acordo com a equação

$$Evd_t = \frac{Evd_o - Evd_{\min}}{Evd_{\max} - Evd_{\min}} \cdot 255 \quad (2)$$

em que

Evd_t - valor do pixel na imagem transformada;

Evd_o - valor do pixel na imagem processada;

Evd_{\min} - valor máximo de pixel na imagem processada ; e

Evd_{\max} - valor mínimo de pixel na imagem processada.

As imagens coloridas originais apresentavam, nas bordas, pixels com valores nulos, provenientes possivelmente de problemas na aquisição de imagens pela placa. Para não influenciar o resultado dos testes, foram eliminadas as 10 primeiras e as 10 últimas colunas de pixels das imagens, assim como as 10 primeiras e as 10 últimas linhas, reduzindo a dimensão das imagens processadas para 1372 (H) por 1019 (V) pixels.

Uma rotina foi desenvolvida no programa computacional MATLAB, para que cada uma de cinco pessoas pudesse obter manualmente, por tentativa, um valor de limiar que segmentasse adequadamente as classes folha e fundo nas imagens normalizadas. Essa rotina apresentava, inicialmente, a imagem colorida original e uma imagem binária criada, utilizando-se um limiar baixo. A pessoa aumentava ou diminuía o limiar, sem ter acesso ao valor, para não influenciar a limiarização das imagens subseqüentes. A cada alteração do

limiar pela pessoa, o programa apresentava a nova imagem binária acompanhada da imagem original. No momento em que a pessoa considerava a imagem binária satisfatória, o programa salvava, em um arquivo, o nome da imagem e o valor do limiar. Ao final, para cada imagem, uma média aritmética foi calculada, usando-se os limiares obtidos pelas cinco pessoas. Esses limiares médios, assim obtidos, foram utilizados para criar as imagens binárias de referência para avaliação dos métodos automáticos de limiarização.

Foram utilizados dois métodos automáticos de limiarização: iterativo (Yang et al., 2001) e bayesiano (Gonzales & Woods, 1992). O método iterativo assume que o valor do limiar ótimo pode ser obtido, calculando-se a média dos valores médios dos pixels nas duas classes de um histograma bimodal. O histograma da imagem é percorrido, para encontrar o valor de limiar que promove o maior grau de separação entre as duas classes. O método bayesiano considera o histograma da imagem como uma estimativa da função densidade de probabilidade do brilho. Assumindo-se que os histogramas das imagens apresentavam uma distribuição gaussiana bimodal, o limiar que minimiza a probabilidade de erros de classificação (limiar ótimo) foi estimado por meio da equação (Gonzales & Woods, 1992)

$$AT^2 + BT + C = 0 \quad (3)$$

em que

T – valor do limiar ótimo.

Os fatores A, B e C foram calculados por meio das equações

$$A = \sigma_1^2 - \sigma_2^2 \quad (4)$$

$$B = 2(\mu_1\sigma_2^2 - \mu_2\sigma_1^2) \quad (5)$$

$$C = \sigma_1^2\mu_2^2 - \sigma_2^2\mu_1^2 + 2\sigma_1^2\sigma_2^2 \ln(\sigma_2P_1 / \sigma_1P_2) \quad (6)$$

em que

σ_1^2 – variância da classe 1 da imagem;

σ_2^2 – variância da classe 2 da imagem;

μ_1 – média dos níveis de cinza da classe 1;

μ_2 – média dos níveis de cinza da classe 2;

P_1 – probabilidade de ocorrência da classe 1; e

P_2 – probabilidade de ocorrência da classe 2.

As médias, as variâncias e as probabilidades de ocorrência das classes na imagem foram estimadas, minimizando-se a função do erro médio quadrático entre a função gaussiana bimodal e os valores do histograma da imagem. A minimização foi realizada, utilizando-se o método do gradiente descendente (Mateus & Luna, 1986).

Os valores dos limiares foram comparados por meio de uma regressão linear sem intercepto entre os valores do limiar manual e dos métodos automáticos de limiarização (Yang et al. 2001). Além disso, as imagens binárias de referência e as imagens binárias das mesmas plantas, criadas com os dois métodos automáticos de limiarização, foram comparadas, utilizando-se uma rotina desenvolvida no programa computacional MATLAB para criar a matriz de erros ou de contingência. Por meio dessa matriz, é possível verificar a exatidão da classificação em cada classe, acessando-se os erros de comissão e de omissão (Jensen, 1996). Os erros de comissão das classes foram calculados por meio da equação

$$EC_i = \frac{pe_i}{pc_i} \cdot 100 \quad (7)$$

em que

EC_i – erro de comissão da classe i ;

pe_i – número de pixels da classe i atribuídos a outra classe; e

pc_i – número total de pixels da classe i na imagem binária de referência.

Utilizando-se o número total de pixels corretamente classificados na imagem, a diagonal da matriz de erros, calculou-se a exatidão global da classificação (EG):

$$EG = \frac{pc}{pt} \cdot 100 \quad (8)$$

em que

EG – exatidão global da classificação;

pc – número de pixels corretamente classificados; e

pt – número total de pixels na imagem.

Foram criadas ainda as imagens-diferença, comparando-se as imagens resultantes da limiarização automática com as imagens resultantes da limiarização manual. Nessas imagens binárias, os pixels classificados da mesma forma pelos dois métodos são atribuídos a uma classe enquanto os demais pixels são atribuídos a outra.

RESULTADOS E DISCUSSÃO

A Figura 1 ilustra a regressão linear entre os valores dos limiares manuais e automáticos. Os resultados dos dois métodos foram semelhantes, uma vez que as regressões apresentaram valores de β próximos (0,8426 e 0,8917) e r^2 maior que 0,99. Os dois métodos automáticos de limiarização definiram limiares mais baixos que o limiar manual, para todas as imagens.

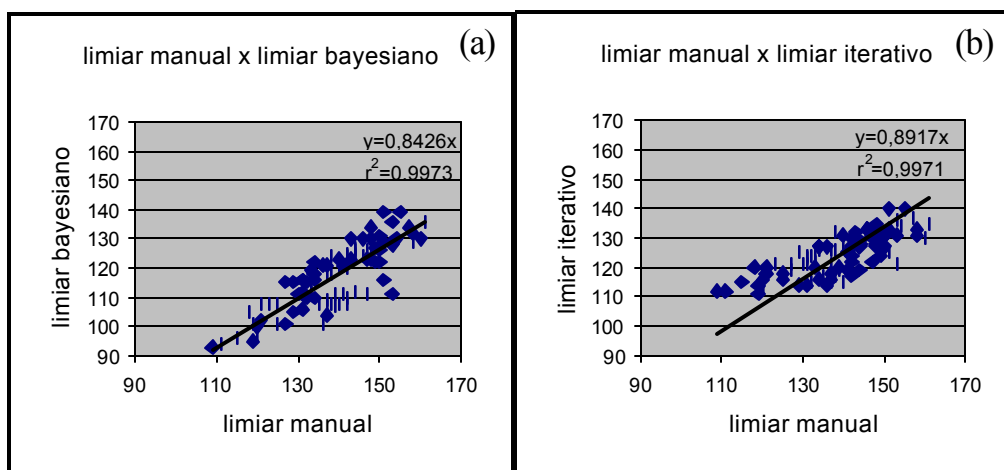


Figura 1. Regressão linear sem intercepto entre os valores do limiar manual e limiares bayesiano (a) e iterativo (b).

A Tabela 2 apresenta a média, o desvio-padrão, o valor máximo e o valor mínimo da exatidão global e dos erros de comissão para a classe folha dos dois métodos automáticos de limiarização, considerando-se o limiar manual como referência. Os resultados obtidos pelos dois métodos automáticos de limiarização foram considerados satisfatórios, com média acima de 99% de exatidão. Na literatura, são encontrados trabalhos como o de Ling & Ruzhitsky (1996) em que um método automático de limiarização foi considerado eficiente com diferenças de -2% a 6% , comparando-se as áreas dos objetos determinados manualmente e na limiarização automática. O algoritmo iterativo apresentou resultados ligeiramente superiores ao algoritmo bayesiano, uma vez que sua exatidão global média foi um pouco maior, com o desvio-padrão e os erros de comissão mínimos e máximos da classe folha um pouco menores. Uma vez que a limiarização divide a imagem em duas classes, e nas imagens processadas, as folhas apresentavam-se com valores mais altos, os erros de classificação foram somente de omissão da classe fundo, devido ao limiar mais baixo definido pelos métodos automáticos.

Tabela 2. Valores médios, máximos e mínimos da exatidão global e erros de comissão da classe folha para o algoritmo bayesiano e o algoritmo iterativo

	Algoritmo iterativo		Algoritmo bayesiano	
	Exatidão global (%)	Erro de comissão da classe folha (%)	Exatidão global (%)	Erro de comissão da classe folha (%)
Média	99,51	0,49	99,24	0,76
Desvio padrão	0,4386	0,4386	0,5989	0,5989
Máximo	100,00	1,89	99,81	2,61
Mínimo	98,11	0	97,39	0,19

A Figura 2 ilustra a normalização e limiarização da imagem de uma planta de milho atacada pela lagarta do cartucho.

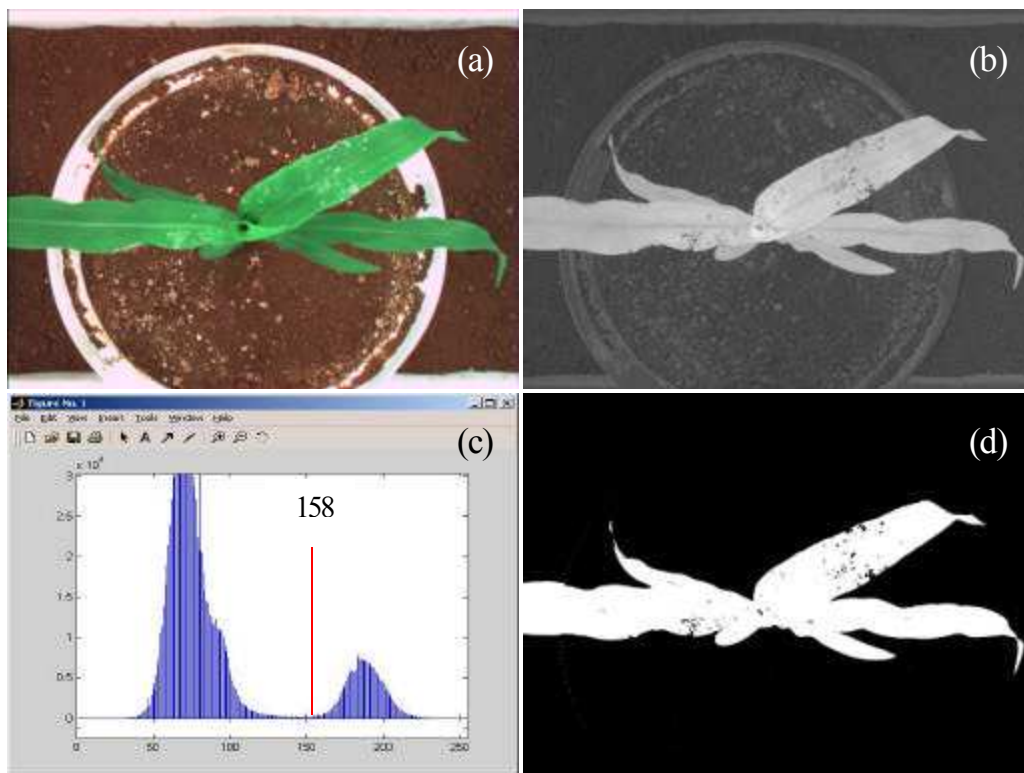


Figura 2. Imagem original de planta atacada pela lagarta do cartucho (a); imagem processada com o índice do excesso de verde normalizado (b); histograma da imagem processada e o limiar manual utilizado para segmentação (c); imagem binária resultante da segmentação com o limiar manual (d).

Na imagem processada (Figura 2b) os pixels representando folhas apresentam-se em tom mais claro que o restante da imagem, inclusive as bordas do vaso que aparecem em branco na imagem original (Figura 2a). Esse resultado é importante pois em condições de campo, especialmente em plantas cultivadas em sistema de plantio direto, a palha sobre o solo vai aparecer em tom mais claro do que as folhas nas imagens originais, da mesma forma que as bordas do vaso nesta imagem.

No histograma da imagem processada (Figura 2c) nota-se a clara distinção das duas classes, separadas por um vale acentuado, mostrando a eficácia do índice do excesso de verde normalizado para realçar os pixels de folhas. Esse realce ocorreu devido às características espectrais das folhas na faixa do visível, onde os pigmentos presentes, especialmente a clorofila, absorvem intensamente a energia nas bandas vermelha e azul enquanto refletem na banda verde. Este fato não ocorre nos demais componentes da imagem (solo, porções atacadas das folhas e bordas do vaso), onde a relação entre as bandas e, conseqüentemente, entre os valores dos pixels, é mais equilibrada.

A Figura 3 ilustra a segmentação da mesma imagem da planta da Figura 2 utilizando-se o limiar iterativo e o limiar bayesiano.

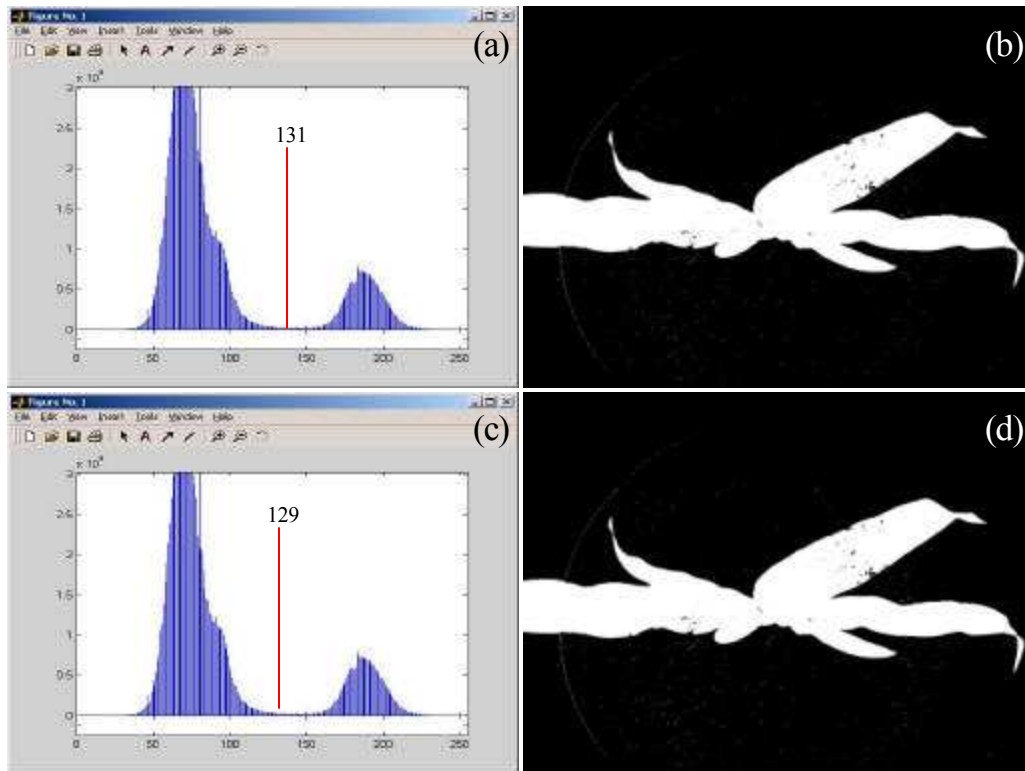


Figura 3. Histograma da imagem processada indicando o valor do limiar iterativo (a); imagem binária criada com o limiar iterativo (b); histograma da imagem processada indicando o valor do limiar bayesiano (c); imagem binária criada com o limiar bayesiano (d).

Comparando as imagens binárias das Figuras 3 e 2, verifica-se que são semelhantes, mostrando a eficácia dos métodos automáticos de limiarização para este caso. Yang et al. (2001) utilizaram a proximidade do valor do limiar, definido automaticamente com o valor do limiar manual como parâmetro para avaliar os métodos automáticos de limiarização. No presente trabalho, embora os valores dos limiares definidos pelos métodos automáticos tenham sido bastante diferentes, em termos numéricos, dos limiares manuais, as imagens binárias foram muito semelhantes, conforme demonstrado pela exatidão global, devido à boa separação entre as classes. Ao se alterar o valor do limiar dentro do vale, o número de pixels que são atribuídos à outra classe é pequeno em relação ao número total de pixels da imagem.

A Figura 4 ilustra as imagens-diferença de uma planta atacada e de uma planta não atacada pela lagarta do cartucho, segmentadas com o método iterativo, em relação à limiarização manual. Nestas imagens, são apresentados, em preto, os pixels classificados de forma diferente pelo método iterativo em relação ao método manual. Verifica-se que, em geral, o erro da limiarização automática ocorreu nas bordas das folhas, das injúrias provocadas pela lagarta e nas bordas do vaso, na transição de um objeto para outro. Estes são os pixels que são atribuídos à outra classe, quando se altera o valor do limiar, ou seja, os pixels que se localizam no vale entre as duas classes, pois, na imagem a transição de uma classe para outra é gradual em termos de níveis de cinza. As imagens de plantas atacadas nos estádios mais avançados apresentaram uma exatidão global ligeiramente menor na classificação, provavelmente devido ao maior número de objetos e, conseqüentemente, maior número de pixels de transição.




Figura 4. Imagem-diferença de uma planta atacada segmentada com o limiar iterativo em relação à limiarização manual (a) e imagem-diferença de uma planta não atacada segmentada com o limiar iterativo em relação à limiarização manual (b).

Com estes resultados, acredita-se que é possível utilizar tanto o algoritmo iterativo quanto o bayesiano para segmentar, automaticamente, imagens de plantas de milho processadas com o índice do excesso de verde normalizado. A principal vantagem da utilização do algoritmo iterativo é sua menor exigência, em termos computacionais, em relação ao algoritmo bayesiano, o que facilita sua implementação em sistemas de visão artificial.

CONCLUSÕES

Neste trabalho, foram avaliados dois métodos automáticos de limiarização, iterativo (Yang et al., 2001) e bayesiano (Gonzales & Woods, 1992), utilizando-se imagens processadas de plantas de milho atacadas e não atacadas pela lagarta do cartucho (*Spodoptera frugiperda*). As imagens originais foram obtidas em três intensidades luminosas e três épocas distintas, que correspondiam a diferentes dias após a infestação, e foram processadas com o índice do excesso de verde normalizado. Os resultados dos métodos automáticos foram comparados com a limiarização das mesmas imagens, utilizando-se o limiar médio obtido manualmente por cinco pessoas.

Os resultados obtidos pelos dois métodos automáticos de limiarização foram satisfatórios, com média acima de 99% de exatidão global, sendo que o algoritmo iterativo apresentou resultados ligeiramente superiores ao algoritmo bayesiano, em termos de exatidão global.

Os resultados mostraram que os dois algoritmos de limiarização automática (iterativo e bayesiano) têm potencial para serem utilizados em um sistema de visão artificial, para identificação de plantas de milho atacadas pela lagarta do cartucho. O algoritmo bayesiano, no entanto, é mais exigente em termos computacionais do que o algoritmo iterativo.

AGRADECIMENTOS

Aos pesquisadores, técnicos e demais funcionários da Embrapa Milho e Sorgo, em Sete Lagoas, MG, por viabilizarem o desenvolvimento dessa pesquisa. À Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) pelo financiamento concedido ao primeiro autor durante o curso de mestrado.

LITERATURA CITADA

- Alchanatis, V.; Peleg, K.; Ziv, M. Classification of tissue culture segments by colour machine vision. *Journal of Agricultural Engineering Research*, London n.55, 299-311, 1993.
- Andreadis, I. & Tsalides, P. Analog computation of image chromaticity *Real-Time Imaging*, London, n.3, p.1 – 6, 1997.
- Battle, J.; Casals, A.; Freixenet, J.; Martí, J. A review on strategies for recognizing natural objects in colour images of outdoor scenes. *Image and Vision Computing*, Amsterdam, n.18 p. 515–530, 2000.
- Carvalho, R.P.L. Pragas do milho.in: Paterniani, E.; Viégas, G.P. (ed.) *Melhoramento e Produção de Milho*. V.2.2 ed. Campinas: Fundação Cargill,. 1987. p. 637 – 712 .
- Fancelli, A.L. & Dourado Neto, D. *Produção de milho*. 1 ed. Guaíba: Livraria e Editora Agropecuária, 2000, 360p.
- Gonzales, R.C. & Woods, R.E. *Digital image processing*. Reading, Massachusetts: Addison-Wesley Publishing Company, 716p, 1992.
- Hemming, J & Rath, T. Computer-vision-based weed identification under field conditions using controlled lighting *Journal of Agricultural Engineering Research*, London. n.78 v.3 p. 233-243, 2001.
- Jensen, J.R. *Introductory digital image processing: a remote sensing perspective*. New York: Prentice Hall, 1996, 318p.
- Leemans, V.; Magein, H.; Destain, M.F. Defect segmentation on ‘jonagold’ apples using colour vision and a bayesian classification method. *Computers and Electronics in Agriculture*, Oxford, v. 23 p. 43–53, 1998.
- Ling, P.P. & Ruzhitsky, V.N. Machine vision techniques for measuring the canopy of tomato seedling *Journal of Agricultural Engineering Research*, London v.65, p.85-95, 1996.
- Luo, X.; Jayas, D.S.; Symons, S.J. Identification of damaged kernels in wheat using a colour machine vision system. *Journal of Cereal Science*, London, 30 p. 49–59, 1999.
- Marques Filho, O. & Vieira Neto, H. *Processamento digital de imagens*. Rio de Janeiro: Brasport, 1999, 406p.
- Mateus, G.R. & Luna, H.P. *Programação não linear*. Belo Horizonte: Editora Gráfica Formato Ltda, 1986, 289p.
- Meyer, G.E.; Mehta, T.; Kocher, M.F.; Mortensen, D.A.; Samal, A. Textural imaging and discriminant analysis for distinguishing weeds for spot spraying. *Transactions of the ASAE*. St. Joseph, v.41 n.4, p.1189 -1197, 1998.

- Oliveira, J.P. & Silva, A.L. Controle químico da lagarta do cartucho (*Spodoptera frugiperda*) em milho, com novo regulador de crescimento. In: XX Congresso Nacional de Milho e Sorgo, 1994 Goiânia, resumos... Goiânia: Associação Brasileira de Milho e Sorgo, 1994. P. 162.
- Oliveira, L.J. Biologia, nutrição quantitativa e danos causados por *Spodoptera frugiperda* (J.E. Smith, 1797) (Lepidoptera: Noctuidae) em milho cultivado em solo corrigido para três níveis de alumínio. Piracicaba: ESALQ, 1987. 125p. Dissertação (mestrado em Ciências Biológicas).
- 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. (ed.). Agricultura de Precisão. Viçosa: UFV, 2000. P. 1-41.
- Simonton, W. & Pease, J. Orientation independent machine vision classification of plant parts. *Journal of Agricultural Engineering Research*, London n. 54, 231-243, 1993.
- Stewart, B.L. & Tian, L.F. Real-time machine vision weed-sensing. ASAE paper 98 - 3033, ASAE, 1998. CD Rom.
- Tang, L.; Tian L.; Steward, B. L. Color image segmentation with genetic algorithm for in-field weed sensing *Transactions of the ASAE*. St. Joseph, v.43 n.4, p.1019 -1027, 2000.
- Tian, L.F. & Slaughter D.C. Environmentally adaptive segmentation algorithm for outdoor image segmentation *Computers and Electronics in Agriculture*, Oxford n. 21 p. 153 -168, 1998.
- Viana, P.A. & COSTA, E.F. Eficiência de inseticidas misturados em óleo vegetal aplicados via irrigação por aspersão para o controle da lagarta do cartucho *Spodoptera Frugiperda* em milho. In: XX Congresso Nacional de Milho e Sorgo, 1994 Goiânia, resumos... Goiânia: Associação Brasileira de Milho e Sorgo, 1994. p. 138.
- Woebbecke, D.M.; Meyer, G.E.; Von Bargen, K.; Mortensen, D.A. Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*. St. Joseph, v.38 n.1, p.259 -269, 1995.
- Yang, L.; Albregtsen, F.; Lonnestad, T.; Grottum, P. A supervised approach to the evaluation of image segmentation methods. *Computer Analysis of Images and Patterns*, Prague p.759-765, 1995

Yang, X; Beyenal, H.; Gary H.; Lewandowski, Z. Evaluation of biofilm image thresholding methods. *Wat. Res.* Vol. 35, p 1149-1158, 2001.

IDENTIFICAÇÃO DE PLANTAS DE MILHO ATACADAS PELA LAGARTA DO CARTUCHO (*Spodoptera frugiperda*) EM IMAGENS COLORIDAS DIGITAIS

RESUMO

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. A lagarta do cartucho (*Spodoptera frugiperda*) é uma das pragas mais importantes na cultura do milho, no Brasil, sendo controlada, principalmente, por meio de produtos químicos. Acredita-se que o controle pode ser realizado de forma localizada com auxílio de um sistema de visão artificial. O objetivo do presente trabalho foi desenvolver e avaliar um algoritmo para identificação de plantas de milho atacadas pela lagarta do cartucho, utilizando-se imagens coloridas digitais. Foram obtidas imagens de plantas atacadas e não atacadas por esse inseto em oito épocas, correspondentes a diferentes dias após a infestação, e em três intensidades de iluminação. O algoritmo proposto consistiu de duas etapas, isto é, processamento e análise das imagens. Na primeira etapa, realizou-se o processamento para obtenção de imagens binárias, segmentando as folhas das plantas dos demais pixels. Na segunda etapa, as imagens foram divididas em blocos e, de acordo com o número de objetos, promoveu-se a classificação das imagens como plantas atacadas ou não atacadas. O algoritmo classificou, corretamente, 94,72 % das 720 imagens testadas.

Palavras-chave: processamento de imagens, visão artificial, agricultura de precisão.

FALL ARMYWORM (*Spodoptera frugiperda*) DAMAGED CORN PLANT IDENTIFICATION ON DIGITAL IMAGES

ABSTRACT

The objectives of Precision agriculture are profit maximization, rationalize the use of agriculture production factors and reduce environmental damage adjusting the agricultural practices to the site demands. The fall armyworm (*Spodoptera frugiperda*) is one of the most important corn pests in Brazil and the use of chemicals is the main control method. It is believed that a site specific control can be done by a machine vision system. The objective of

this work was to develop and evaluate an algorithm for identifying damaged corn plants by the fall armyworm using digital color images. The used images were of damaged and not damaged corn plants in eight stages taken in three light intensities. The proposed algorithm presented two stages: processing and image analysis. On the first stage, the images were processed to create binary images where the leaves were segmented from the other pixels. On the second stage, the images were subdivided into blocks and classified into damaged or not damaged depending on the number of objects found in each block. The algorithm correctly classified 94,72% of 720 images.

Key words : Image processing, machine vision, precision farming

INTRODUÇÃO

A agricultura de precisão, técnica de manejo em que se busca adequar as práticas agrícolas às exigências e potencial produtivo de parcelas dos talhões, agrega um conjunto de técnicas que permitem acessar e monitorar a atividade agrícola em um nível local, integrando a computação, a eletrônica e elevados níveis de controle (Queiroz et al., 2000). O objetivo primordial desta tecnologia é maximizar o lucro do empreendimento agrícola, buscando ainda a racionalização do uso dos fatores de produção (Ribeiro et al., 2000) e do desenvolvimento sustentável da agricultura (Maohua, 2001). De acordo com Plant (2001), a adoção generalizada da agricultura de precisão depende de sua viabilidade econômica, sendo que, a sua implementação é justificada por três critérios básicos a serem atendidos: a existência de variabilidade espacial nos fatores que afetam a produtividade, a possibilidade de identificar e mensurar a causa dessa variabilidade, e que as informações dessas medições possam ser utilizadas para modificar as práticas de manejo e aumentar o lucro, ou reduzir o impacto ambiental. Ainda segundo esse autor, a existência da variabilidade espacial da população de insetos e plantas daninhas, por exemplo, já foi comprovada há mais de cinquenta anos, porém não existia potencial na agricultura mecanizada para manejar efetivamente essa variabilidade.

A disponibilidade de sensores e controladores e a implementação do sistema de posicionamento global (GPS), associado ao uso dos sistemas de informações geográficas e programas computacionais específicos, permitiram o desenvolvimento de máquinas agrícolas capazes de mapear a produtividade e aplicar insumos a taxas variáveis. Foram desenvolvidos, ainda sistemas para obtenção de dados sobre o solo e a cultura, tais como determinadores de umidade, medidores de clorofila e câmeras de sensoriamento remoto portáteis (Blackmore &

Larscheid, 1997). No entanto, Stafford (2000) acredita que antes que a agricultura de precisão seja praticada generalizadamente, será necessário um maior desenvolvimento na área de sensores automáticos para obtenção de dados. Schepers (2000) afirmou que diversos produtores não têm tempo, perícia ou paciência para coletar, analisar e integrar os diversos tipos de informações necessárias para tornar o conceito de agricultura de precisão um sucesso.

Diagnósticos visuais são bastante utilizados na área agrícola, para tomada de decisão por parte do produtor como, por exemplo, deficiências nutricionais, ocorrência de pragas e doenças, classificação e quantificação de plantas daninhas, dentre outros. Assim, os sistemas de visão artificial apresentam grande potencial de utilização como sensores para coleta de dados acerca das condições da cultura para utilização em agricultura de precisão (Pinto et al., 2001). Em um sistema de visão artificial, uma câmera é integrada a um computador por meio de uma placa de aquisição de vídeo. As imagens são processadas por programas computacionais específicos, extraindo-se das imagens as informações de interesse que podem ser armazenadas, ou utilizadas para gerar um sinal para controle de máquinas. Thomas et al. (1995) afirmaram que os sistemas de visão artificial desempenharam papel fundamental no controle de aplicações industriais, principalmente a partir da década de 70. Ainda segundo esses autores, embora tenha havido uma certa estagnação no desenvolvimento dessas técnicas para a indústria, devido ao enfoque das pesquisas acadêmicas, atualmente é raro encontrar uma indústria que não utilize algum tipo de sistema de visão artificial para inspecionar, classificar, medir ou localizar produtos.

Na área agrícola, os desafios para o desenvolvimento de um sistema de visão artificial são maiores do que na indústria. Os principais problemas são: a grande variação na intensidade luminosa e a presença de sombras nas imagens (Steward & Tian, 1998), a variabilidade de cor da luz, de acordo com o dia e com a época do ano (Tian & Slaughter, 1998) e a variabilidade dos produtos agrícolas em cor, tamanho e forma, além das dificuldades impostas pelo ambiente de trabalho dos equipamentos agrícolas (Pinto et al., 2001). Kassler (2001) cita ainda o custo do investimento em equipamentos agrícolas que serão utilizados em apenas alguns meses do ano, devido à sazonalidade da produção e a dificuldade de modificação das práticas existentes para simplificar o desenvolvimento das máquinas.

No entanto, na literatura científica, são encontrados diversos trabalhos utilizando sistemas de visão artificial na área agrícola. Tillett et al. (2001) desenvolveram um sistema de visão artificial capaz de estimar, automaticamente, o número de plantas cultivadas e de plantas daninhas, assim como a área coberta pelas mesmas, permitindo o mapeamento em

tempo real para aplicação localizada de herbicidas. McFarlane et al. (1997) desenvolveram algoritmos de processamento de imagens para realizar medições, a serem utilizadas na poda de videiras, localizando com eficácia de 80 a 95% os pontos essenciais para realização dessa prática. Borhan & Panigrahi (1999) estimaram o teor de nitrogênio em folhas de batata. Kacira et al. (1999) utilizaram este sistema para detecção de estresse hídrico, em plantas cultivadas em ambiente controlado. Steenhoek et al. (1999) avaliaram danos em grãos de milho, obtendo concordância de 88% com a classificação oficial. Diversos trabalhos são encontrados, ainda, utilizando visão artificial para classificação e avaliação de produtos agrícolas, tais como pistache (Ghazanfari et al., 1997), folhas de fumo (Zhang et al., 1997), maçãs (Leemans et al., 1998), batatas (Tao et al., 1995) e germinação de sementes (Ureña et al., 2001)

A lagarta do cartucho (*Spodoptera frugiperda*) é considerada uma das pragas mais importantes na cultura do milho, em todas as regiões do Brasil (Cruz, 1995; Fancelli & Dourado Neto, 2000). A principal forma de controle da lagarta do cartucho consiste na utilização de produtos químicos que, na maioria das vezes, possuem amplo espectro de ação, ocasionando a eliminação dos agentes naturais de controle (Cruz et al., 2000). As técnicas do manejo integrado de pragas (MIP) recomendam a aplicação desses produtos de acordo com a percentagem de plantas atacadas, identificadas visualmente por pessoal treinado.

Uma grande preocupação, em nível mundial, consiste na resistência de insetos, ácaros e doenças fitopatogênicas aos inseticidas, acaricidas e fungicidas, respectivamente (Conceição, 2000). As principais conseqüências da resistência dos insetos aos defensivos são a aplicação mais freqüente, o aumento na dosagem do produto e a substituição por um outro composto, geralmente mais caro e mais tóxico, promovendo maior contaminação ambiental, destruição dos inimigos naturais e elevação dos custos de controle da praga (Omoto et al., 2000). Guedes & Ribeiro (2000) consideraram que a utilidade dos inseticidas tem sido limitada pela evolução da resistência a estes compostos, em várias pragas de grande importância no Brasil. Omoto et al. (2000) realizaram um monitoramento da susceptibilidade de populações de *S. frugiperda* a inseticidas tradicionais, no Brasil, e os resultados obtidos indicaram a necessidade de implementação de um programa de manejo da resistência desta praga na cultura do milho.

A manutenção de refúgios sem aplicação de inseticidas, dentro dos campos agrícolas, é sugerida como um mecanismo para manejo da resistência aos pesticidas e conservação dos inimigos naturais. O manejo integrado de pragas, em sítio específico, pode criar esses refúgios (Midgarden et al., 1997) preservando os genótipos suscetíveis, os inimigos naturais e

reduzindo a aplicação de inseticidas (Weisz et al.,1996). Além disto, a agricultura de precisão possibilita a utilização racional dos defensivos agrícolas, em razão de sua aplicação no momento apropriado, nos alvos predeterminados e nas quantidades adequadas, reduzindo custos e preservando o ambiente (Conceição, 2000), uma vez que, em geral, a distribuição espacial de pragas ocorre de maneira agregada ou em reboleira (Viana, 2000). Os resultados obtidos por Weisz et al. (1996) no manejo, em sítio específico, de pragas na cultura da batata mostraram este potencial, com redução na aplicação de inseticidas em 45 a 70%, dependendo da época do ano.

Midgarden et al. (1997) conduziram experimento para avaliar o impacto desta técnica sobre o desenvolvimento de resistência do besouro-da-batata-do-colorado (*Leptinotarsa decemlineata*) a inseticidas e sobre a população de inimigos naturais, em campos comerciais de batata. Três campos com 1,2 ha foram manejados, divididos em blocos de manejo de 0,04 ha, tratados somente quando a população da praga atingia o limiar econômico. Esse tratamento foi comparado com o MIP convencional em campos adicionais de 1,2 ha, em que o inseticida era aplicado em todo o campo, quando a média excedia o limiar. Todos os campos tratados de acordo com o MIP convencional apresentaram aumento significativo na resistência da praga ao inseticida, enquanto nos campos manejados de forma localizada pequena ou nenhuma resistência foi observada. As populações de inimigos naturais apresentaram-se maiores nos campos tratados de modo localizado. Os autores concluíram que o MIP, em sítio específico, apresenta potencial para reduzir o desenvolvimento de resistência a inseticidas e conservar os inimigos naturais.

Acredita-se que a lagarta do cartucho, no Brasil, apresenta características que podem permitir seu controle localizado com o auxílio de um sistema de visão artificial, com benefícios para todo o sistema agrícola. A identificação de plantas atacadas pela lagarta do cartucho poderia gerar informações para a elaboração de mapas de aplicação localizada de inseticidas, ou até mesmo controlar em tempo real um pulverizador capaz de aplicar o produto somente nas plantas atacadas. Acredita-se que os dois métodos apresentam potencial para redução do uso de inseticidas, da contaminação ambiental, do prejuízo à população de inimigos naturais e no desenvolvimento de resistência da lagarta do cartucho aos produtos utilizados. Neste contexto, o objetivo do presente trabalho foi desenvolver e avaliar um algoritmo para identificação de plantas de milho atacadas pela lagarta do cartucho, utilizando-se imagens coloridas digitais.

MATERIAL E MÉTODOS

O trabalho foi conduzido utilizando-se 30 vasos de 15 litros com solo peneirado e adubado com adubo formulado NPK 4-14-8 na quantidade de 3,00 kg por tonelada de solo, mantidos em casa-de-vegetação, nas dependências da Embrapa Milho e Sorgo, em Sete Lagoas, MG. Em cada vaso foram semeadas três sementes do híbrido triplo HT971011 no dia 26/06/2001. As plantas emergiram no dia 03/07/2001 e, após uma semana, foram desbastadas para uma planta por vaso. Quinze dias após a emergência, foram escolhidas, aleatoriamente, quinze plantas para infestação com 10 lagartas de *Spodoptera frugiperda* eclodidas no dia anterior. Imagens de 15 plantas atacadas e 15 plantas não atacadas pela lagarta do cartucho foram obtidas, em três intensidades de iluminação e em oito épocas, correspondentes a diferentes dias após a infestação, perfazendo um total de 720 imagens.

As imagens foram coletadas com a câmera posicionada a um metro acima das folhas mais altas das plantas. Utilizou-se uma câmera digital DUNCANTECH, modelo MS3100, conectada a um microcomputador por meio de uma placa de aquisição de vídeo da National Instruments, modelo PCI 1424. As imagens coloridas RGB foram salvas com dimensões de 1392 (H) e 1039 (V) pixels no formato TIF (“tagged image file format”). A câmera utilizada era equipada com 3 CCD (“charge-coupled device”), os quais permitiam o controle do ganho e do tempo de exposição em cada sensor. 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 permitia o controle manual da abertura da íris, em que o “f-stop” foi definido em 3,5. A Tabela 1 apresenta o ganho e o tempo 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

Para obtenção das imagens sob condições de iluminação controlada, construiu-se uma estrutura metálica com dimensões 1,50m por 1,50m e 2,00m de altura, 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 obtenção das três intensidades de iluminação, os quatro refletores foram mantidos acesos e as demais lâmpadas foram acesas, sucessivamente, duas a duas.

As imagens coloridas originais apresentavam, nas suas bordas, pixels com valores nulos, provenientes, possivelmente, de problemas na aquisição das imagens pela placa. Para não influenciar os resultados dos testes, foram eliminadas as 10 primeiras e as 10 últimas colunas de pixels das imagens, assim como as 10 primeiras e as 10 últimas linhas, reduzindo-se a dimensão das imagens processadas para 1372 (H) por 1019 (V) pixels.

O algoritmo utilizado neste trabalho foi desenvolvido no Laboratório de Projeto de Máquinas e Visão Artificial do Departamento de Engenharia Agrícola da Universidade Federal de Viçosa, e implementado no programa computacional MATLAB com o pacote de ferramentas para processamento de imagens. O algoritmo foi dividido em duas etapas, isto é, processamento e análise das imagens. A primeira etapa tinha como objetivo final obter uma imagem binária, em que as folhas da planta fossem representadas por pixels de valor 0, e os demais constituintes da imagem (solo, injúrias provocadas pela lagarta, e as bordas do vaso) fossem representados por pixels de valor 1. A segunda etapa tinha como objetivo a classificação da informação pictorial da imagem binária em planta atacada ou não.

A Figura 1 ilustra os passos da etapa de processamento das imagens. As imagens originais foram processadas com o índice do excesso de verde normalizado, de acordo com a equação

$$Evd = \frac{2 \cdot Vd - Vm - Az}{Vm + Vd + Az} \quad (1)$$

em que

Evd - excesso de verde normalizado;

Vd - valor do pixel na banda verde;

Vm - valor do pixel na banda vermelha; e

Az - valor do pixel na banda azul.

Tendo em vista que as imagens processadas apresentavam valores entre -1 e 2 procedeu-se a uma transformação linear nos valores dos pixels, criando-se imagens em 256 tons de cinza, de acordo com a equação

$$Evd_t = \frac{Evd_o - Evd_{min}}{Evd_{max} - Evd_{min}} \cdot 255 \quad (2)$$

em que

Evd_t - valor do pixel na imagem transformada;

Evd_o - valor do pixel na imagem processada;

Evd_{max} - valor máximo de pixel na imagem processada ; e

Evd_{min} - valor mínimo de pixel na imagem processada.

No próximo passo, as imagens em tons de cinza foram segmentadas, utilizando o algoritmo iterativo (Yang et al., 2001) e criando-se imagens binárias, em que os pixels relativos às folhas receberam valor 0 e os do fundo valor 1. Devido à presença de ruído impulsivo nas imagens binárias, procedeu-se à filtragem das mesmas utilizando-se um filtro de mediana (Marques Filho & Vieira Neto, 1999) de dimensão 3x3 pixels.

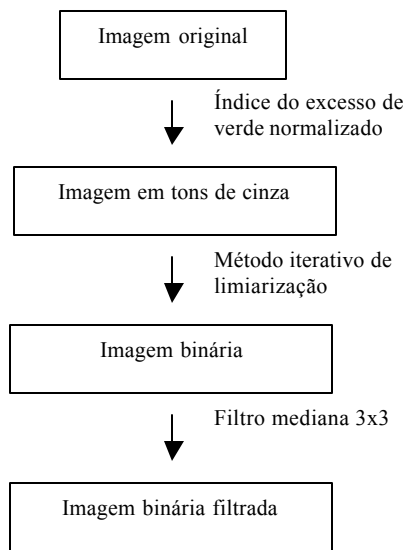


Figura 1. Passos da etapa de processamento das imagens.

A Figura 2 ilustra os passos da etapa de análise das imagens processadas. Nessa etapa, o primeiro passo foi a subdivisão das imagens em blocos, objetivando eliminar as porções das imagens com predominância de solo e concentrar a proporção de injúrias em cada bloco, facilitando assim a classificação. As imagens foram subdivididas em 12 blocos, sendo que os que apresentavam menos de 5% de pixels de folhas foram descartados. Definiu-se um objeto como um grupo de pixels conectados de valor 1. Em seguida, realizou-se a identificação e

contagem dos objetos nos blocos selecionados. De acordo com o número de objetos encontrados no bloco, o mesmo foi classificado como folha atacada ou não atacada.

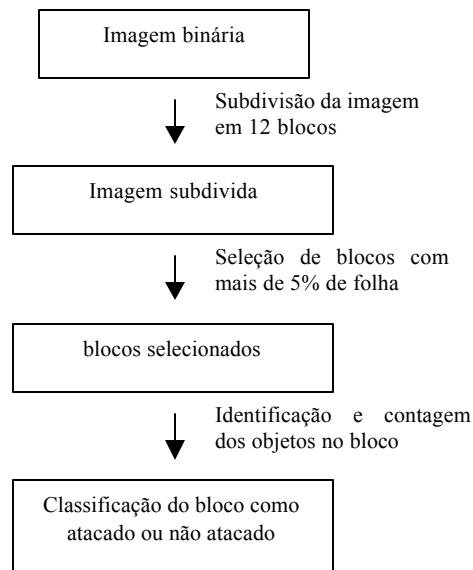


Figura 2. Passos da etapa de análise e classificação das imagens processadas.

Para escolha dos valores do número de objetos no bloco, a serem utilizados como limiar para classificação das imagens como planta atacada ou não atacada, foram utilizadas imagens de três grupos de 10 plantas (5 atacadas e 5 não atacadas), em três épocas, com as imagens de cada grupo em uma intensidade de iluminação. Foram utilizadas imagens das plantas aos 17, 20 e 23 dias após a emergência (DAE), que correspondiam a 2, 5 e 8 dias após a infestação (DAI) pela lagarta do cartucho. Procedeu-se à contagem dos objetos nos blocos sendo os quatro valores de limiares que proporcionaram menor erro na classificação selecionados para teste no conjunto total das imagens.

Procedeu-se à classificação das 720 imagens utilizando-se os valores definidos na amostragem como critério para classificação dos blocos. Quando a imagem apresentava, pelo menos, um bloco classificado como planta atacada, ela era classificada como tal. Em função do número de acertos na classificação final, foi selecionado o valor do limiar mais adequado para classificação.

RESULTADOS E DISCUSSÃO

A Figura 3 ilustra a etapa de processamento e a subdivisão da imagem binária de uma planta atacada pela lagarta do cartucho. O índice do excesso de verde normalizado foi eficaz para realçar as folhas das plantas, tomando os pixels mais claros do que o solo, o vaso e injúrias provocadas pela lagarta (Figura 3b), permitindo a segmentação das folhas dos demais pixels (Figura 3c).




Figura 3. Imagem original (a); imagem processada com o índice do excesso de verde normalizado (b); imagem binária criada pela segmentação com o método iterativo (c); e imagem binária subdividida em 12 blocos (d).

A Figura 3d ilustra a subdivisão da imagem em 12 blocos de 300x300 pixels. Os blocos que apresentavam mais de 95% dos pixels de fundo foram descartados. Os demais blocos foram selecionados para a próxima etapa, isto é, a identificação e contagem dos objetos. Com isso, dos 8640 blocos de 300x300 pixels das 720 imagens coletadas no experimento, 5406 blocos foram selecionados para identificação da presença de injúrias provocadas pela lagarta do cartucho, reduzindo o tempo de processamento.

Os quatro valores que apresentaram menor erro na classificação das 90 imagens de treinamento (8, 9, 10 e 11 objetos) foram utilizados como limiar para classificar as plantas como atacadas ou não atacadas. A Tabela 2 apresenta os erros de classificação das plantas,

utilizando os quatro valores do número de objetos como limiar. O erro de classificação foi maior no grupo de plantas não atacadas do que no grupo de plantas atacadas, com exceção da classificação em que utilizou-se o valor de 11 objetos como limiar. Este resultado é interessante para implementação do sistema no campo, pois, o erro por não aplicar o defensivo em uma planta atacada tende a ser mais grave do que aplicá-lo em uma planta não atacada. O menor valor do número de objeto como limiar (oito) privilegiou a classificação das plantas atacadas, proporcionando menor erro para este grupo; no entanto, promoveu maior erro de classificação nas plantas não atacadas. Já o maior limiar (onze) promoveu o menor erro no grupo de plantas não atacadas e o maior erro no grupo de plantas atacadas.

Tabela 2. Erros de classificação utilizando os valores 8, 9, 10 e 11 de número de objetos como limiar para classificação das plantas como atacadas e não atacadas

Nº de objetos	Atacadas				Não atacadas			
	8	9	10	11	8	9	10	11
Nº erros classificação	7	9	12	37	73	46	26	17
% erro	1,94	2,50	3,33	10,28	20,28	12,78	7,22	4,72

A Tabela 3 apresenta os erros totais de classificação, utilizando os valores 8, 9, 10 e 11 do número de objetos como limiar. Considerando o erro total, o melhor resultado foi o valor de 10 objetos com erro total de 5,28%. Encontram-se resultados semelhantes na literatura. Vízányó & Felfoldi (2000) avaliaram técnica de processamento de imagens para identificação de cogumelos atacados por doenças, obtendo resultados considerados aceitáveis, pois 85% do material de teste foram corretamente classificados. Steenhoek et al. (1999) desenvolveram um sistema de visão artificial para avaliar danos em amostras de grãos de milho, obtendo concordância de 88% com a classificação oficial. Ghazanfari et al. (1997) avaliaram árvores de decisão e redes neurais artificiais, classificando corretamente imagens de pistache em 87,1% e 94,8% das amostras, respectivamente.

Tabela 3. Erros totais de classificação utilizando os valores 8, 9, 10 e 11 do número de objetos

Nº de objetos	8	9	10	11
Nº erros classificação	80	55	38	54
% erro	11,11	7,64	5,28	7,50

A Tabela 4 apresenta o número de plantas classificadas incorretamente, utilizando 10 objetos como limiar e a percentagem de erro em relação ao número de plantas atacadas, não atacadas e total. O algoritmo só classificou plantas atacadas incorretamente nos dois primeiros estádios, em que as injúrias provocadas pela lagarta ainda estavam restritas a pequenas porções da folha, em pequeno número e com pequenas dimensões. O maior erro para plantas atacadas ocorreu na primeira época, 17 DAE / 2 DAI, com 2,22% de erro. Ao contrário do observado nas plantas atacadas, a maior parte dos erros na classificação das plantas não atacadas ocorreu nos estádios mais avançados, em que a nervura central das folhas estava mais desenvolvida, com coloração mais clara, e o cartucho de algumas plantas foi segmentado como vários objetos. O maior erro ocorreu na época 24 DAE, com 3,89 % de erro.

Tabela 4. Número de plantas classificadas incorretamente, percentagem de erro em relação ao número de plantas atacadas, não atacadas e total utilizando o valor de 10 objetos como limiar para diferentes dias após a emergência e dias após a infestação pela lagarta do cartucho

Época	Plantas atacadas		Plantas não atacadas		Total
	Nº de erros	Erro (%)	Nº de erros	Erro (%)	Erro (%)
17 DAE / 2 DAI	8	2,22	2	0,56	1,39
18 DAE / 3 DAI	4	1,11	2	0,56	0,83
19 DAE / 4 DAI	0	0	1	0,28	0,14
20 DAE / 5 DAI	0	0	1	0,28	0,14
21 DAE / 6 DAI	0	0	0	0	0
22 DAE / 7 DAI	0	0	2	0,56	0,28
23 DAE / 8 DAI	0	0	4	1,11	0,56
24 DAE / 9 DAI	0	0	14	3,89	1,94
Total	12	3,33	26	7,22	5,28

A Figura 4 ilustra blocos corretamente classificados, utilizando-se 10 objetos como limiar para classificação. Nos blocos de plantas atacadas (Figuras 4a e 4b), pode-se verificar a forma típica do ataque pela lagarta do cartucho, com diversas lesões. A Figura 4c ilustra a situação que ocorre nas plantas mais desenvolvidas onde a nervura, de cor mais clara, é segmentada como fundo. A Figura 4d ilustra outra situação frequente em plantas mais desenvolvidas, onde o cartucho da planta é segmentado como um objeto.




Figura 4. Blocos corretamente classificados como atacados pela lagarta do cartucho de plantas atacadas (a e b) e de plantas não atacadas (c e d).

A Figura 5 ilustra blocos de plantas atacadas e não atacadas, classificados incorretamente pelo algoritmo. Na Figura 5a, ocorreu um ataque atípico na borda da folha, de modo que essas injúrias foram agrupadas como o mesmo objeto do fundo. Na Figura 5b, o ataque estava em um estágio inicial, com poucas injúrias visíveis. Na figura 5c, a nervura não foi segmentada como um único objeto, provocando o erro na classificação. Da mesma forma, na figura 5d, o cartucho da planta foi segmentado em mais de um objeto.




Figura 5. Blocos incorretamente classificados, de plantas atacadas (a e b) e de plantas não atacadas (c e d).

CONCLUSÕES

Neste trabalho, foi implementado e avaliado um algoritmo para identificação de plantas de milho atacadas pela lagarta do cartucho, utilizando-se imagens monocromáticas obtidas pelo processamento de imagens coloridas digitais. As imagens foram processadas com o índice do excesso de verde normalizado, segmentadas utilizando-se o método iterativo de limiarização, subdivididas em blocos e classificadas em função do número de objetos presentes. O algoritmo foi avaliado em imagens de plantas atacadas e não atacadas, obtidas em três intensidades de iluminação em oito épocas, correspondentes a diferentes dias após a infestação.

Os menores erros de identificação foram obtidos quando 90 imagens de um grupo de teste foram classificadas utilizando-se limiares de número de objetos 8, 9, 10 e 11.

O resultado da classificação de 720 imagens, utilizando os quatro valores como limiar, mostrou que o valor mais baixo privilegiou a classificação das plantas atacadas, enquanto o valor mais alto privilegiou a classificação das plantas não atacadas. O melhor resultado foi obtido com o valor de 10 objetos como limiar, com erro de classificação de 5,28% para as 720 imagens testadas.

O algoritmo proposto promoveu maior erro de classificação nas plantas não atacadas, especialmente nos estádios mais avançados de desenvolvimento. O erro de classificação de plantas atacadas ocorreu, principalmente, nos primeiros estádios de desenvolvimento.

AGRADECIMENTOS

Aos pesquisadores, técnicos e demais funcionários da Embrapa Milho e Sorgo, em Sete Lagoas, MG, por viabilizarem o desenvolvimento dessa pesquisa. À Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) pelo financiamento concedido ao primeiro autor durante o curso de mestrado.

LITERATURA CITADA

- Blackmore, B. S. & Larscheid, G. Strategies for Managing Variability. 1st European Conference on Precision Agriculture, Warwick, 1997.
- Borhan, M.S. & Panigrahi, S. Multi-spectral imaging techniques for nitrogen determination in potato leaf. ASAE Paper No. 995005, ASAE, 1999.
- Conceição, M.Z. Manejo integrado em defesa vegetal. In: Manejo integrado – doenças, pragas e plantas daninhas. Zambolim, L (ed.) Viçosa, 2000
- Cruz, I. A lagarta do cartucho na cultura do milho. Sete Lagoas: EMBRAPA-CNPMS,. 42P. (EMBRAPA-CNPMS. Circular Técnica, 21). 1995.
- Cruz, Il.; Figueiredo, M.L.C.; Alberton, M. Eficiência de novos piretróides no controle da *Spodoptera frugiperda* em milho e seletividade ao predador *Doru luteipes* in: XXIII congresso nacional de milho e sorgo, resumos expandidos, Uberlândia, Associação Brasileira de Milho e Sorgo, 2000.
- Fancelli, A.L. & Dourado Neto, D. Produção de milho. 1 ed. Guaíba: Livraria e Editora Agropecuária, 2000, 360p.

- Ghazanfari, A.; Irudayaraj, J.; Kusalik, A.; Romaniuk, M. Machine vision grading of pistachio nuts using fourier descriptors Journal of Agricultural Engineering Research, London n.68, p. 247-252, 1997.
- Guedes, R.N. & Ribeiro, B.M. Limitações de métodos de controle para o manejo de pragas. In: Manejo integrado – doenças, pragas e plantas daninhas. Zambolim, L (ed.) Viçosa, 2000.
- Kacira, M.; Ling, P.P.; Short, T.H. Non-contact sensing of plant water stress by infrared thermometry and image processing ASAE paper n. 995004, ASAE,1999.
- Kassler, M. Agricultural automation in the new millennium. Computers and Electronics in Agriculture, Oxford n. 30 p. 237–240, 2001.
- Leemans, V.; Magein, H.; Destain, M.F. Defects segmentation on ‘Golden Delicious’ apples by using colour machine vision Computers and Electronics in Agriculture, Oxford, n. 20 p. 117–130, 1998.
- Maohua, W. Possible adoption of precision agriculture for developing countries at the threshold of the new millennium. Computers and Electronics in Agriculture, Oxford n. 30 p. 45–50, 2001.
- Marques Filho, O. & Vieira Neto, H. Processamento digital de imagens. Rio de Janeiro: Brasport, 1999, 406p.
- McFarlane, N.J.B.; Tisseyre, B.; Sinfort, C.; Tillett, R.D.; Sevilla, F. Image analysis for pruning of long wood grape vines. Journal of Agricultural Engineering Research, London n.66, p. 111-119, 1997.
- Midgarden, D.; Fleischer, S.J.; Weisz, R.; Smilowitz, Z. Site-specific integrated pest management impact on development of esfenvalerate resistance in Colorado potato beetle (Coleoptera:Chrysomelidae) and on densities of natural enemies. Journal of Economic Entomology, Lanham n. 90 v. 4 p. 855-867, 1997.
- Omoto, C.; Schmidt, F.B.; Diez-Rodriguez, G.I.; Silva, R.B. Resistência de *Spodoptera frugiperda* a inseticidas no Brasil: situação atual e perspectivas. in: XXIII congresso nacional de milho e sorgo, resumos expandidos, Uberlândia, Associação Brasileira de Milho e Sorgo, 2000.
- 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.
- Plant, R.E. Site-specific management: the application of information technology to crop production. Computers and Electronics in Agriculture, Oxford n. 30 p. 9–29, 2001.

- 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. (ed.). Agricultura de Precisão. Viçosa: UFV, 2000. P. 1-41.
- Ribeiro, C.A.A.S.; Varella, C.A.A.; Sena Jr., D.G.; SOARES, V.P. Sistemas de Informações Geográficas. In: Borém, A.; Giudice, M.P.; Queiroz, D.M.; Mantovani, E.C.; Ferreira, L.R.; Valle, F.X.R.; Gomide, R.L. (ed.). Agricultura de Precisão. Viçosa: UFV, 2000. P. 381-407.
- Schepers, J.S. World trend in precision agriculture. in: XXIII congresso nacional de milho e sorgo, resumos expandidos, Uberlândia, Associação Brasileira de Milho e Sorgo, 2000.
- Stafford, J.V. Implementing precision agriculture in the 21st century. Journal of Agricultural Engineering Research, London n.76, p. 267-275, 2000.
- Steenhoek, L.; Misra, M.; Hurburgh Jr., C.R.; Bern, C. Implementing a computer vision system for corn kernel damage evaluation ASAE Paper n. 99-3199, ASAE, 1999.
- Stewart, B.L. & Tian, L.F. Real-time machine vision weed-sensing. ASAE paper 98 - 3033, ASAE, 1998. CD Rom.
- Tao, Y.; Morrow, C.T.; Heinemann, P.H.; Sommer, H.J. Fourier-based separation technique for shape grading of potatoes using machine vision. Transactions of the ASAE, St Joseph, n.3 v. 38, 1995.
- Thomas, A.D.H.; Rodd, M.G.; Holt, J.D.; Neill, C.J. Real-time industrial visual inspection: a review. Real Time Imaging, London, n.1, p. 139-158, 1995.
- Tian, L.F. & Slaughter D.C. Environmentally adaptive segmentation algorithm for outdoor image segmentation Computers and Electronics in Agriculture, Oxford n. 21 p. 153 –168, 1998.
- Tillett, N.D.; Hague, T.; Miles, S.J. A field assessment of a potential method for weed and crop mapping on the basis of crop planting geometry. Computers and Electronics in Agriculture, Oxford n.32 p. 229–246, 2001.
- Ureña, R.; Rodríguez, F.; Berenguel, M.A. machine vision system for seeds germination quality evaluation using fuzzy logic Computers and Electronics in Agriculture, Oxford, n. 32 p. 1–20, 2001.
- Viana, P.A. Manejo de pragas na cultura do milho. in: XXIII congresso nacional de milho e sorgo, resumos expandidos, Uberlândia, Associação Brasileira de Milho e Sorgo, 2000.
- Vízhányó, T. & Felföldi, J. Enhancing colour differences in images of diseased mushrooms. Computers and Electronics in Agriculture, Oxford, n.26 p.187–198, 2000.

- Weisz, R.; Fleischer, S.; Smilowitz, Z. Site-specific integrate pest management for high-value crops: impact on potato pest management. *Journal of Economic Entomology*, Lanham n.89 v.2, p. 501-509, 1996.
- Yang, X; Beyenal, H.; Gary H.; Lewandowski, Z. Evaluation of biofilm image thresholding methods. *Wat. Res.* Vol. 35, p 1149-1158, 2001.
- Zhang, J.; Sokhansanj, S.; Wu, S.; Fang, R.; Yang, W. A trainabl grading system for tobacco leaves. *Computers and Electronics in Agriculture*, Oxford n.16 p. 231–244, 1997.

CONCLUSÕES GERAIS

O objetivo deste trabalho foi desenvolver e avaliar um algoritmo para identificação de plantas de milho atacadas pela lagarta do cartucho, utilizando-se imagens coloridas digitais. Buscou-se avaliar, estatisticamente, os efeitos da intensidade luminosa, da presença ou não de injúrias provocadas pela lagarta do cartucho, e do estágio de desenvolvimento das plantas sobre o valor de limiar mais adequado, além de implementar e avaliar dois métodos de limiarização automática de imagens monocromáticas. Foram utilizadas imagens de plantas atacadas e não atacadas por esse inseto, em três intensidades de iluminação em oito épocas, correspondentes a diferentes dias após a infestação pela lagarta do cartucho.

Os fatores ataque, iluminação e estágio de desenvolvimento foram significativos ao nível de 1% de probabilidade pelo teste F, assim como a interação estágio-ataque sobre os valores dos limiares manuais de imagens de plantas obtidas em três épocas distintas. O desdobramento dessa interação mostrou que os limiares para plantas atacadas e não atacadas foram diferentes, somente, para as plantas mais desenvolvidas e com injúrias mais acentuadas, possivelmente devido à proporção entre pixels representando folhas e fundo.

As interações ataque-iluminação e estágio-iluminação não se mostraram significativas no valor do limiar, ao nível de 1% de probabilidade pelo teste F.

Os resultados dos dois métodos automáticos de limiarização foram satisfatórios, com média acima de 99% de exatidão global, quando comparados com a limiarização manual. O algoritmo iterativo apresentou resultados ligeiramente superiores ao algoritmo bayesiano, em termos de exatidão global.

Os resultados mostraram que os dois algoritmos de limiarização automática (iterativo e bayesiano) têm potencial para serem utilizados em um sistema de visão artificial, para identificação de plantas de milho atacadas pela lagarta do cartucho. O algoritmo bayesiano, no entanto, é mais exigente em termos computacionais do que o algoritmo iterativo.

Na avaliação do algoritmo proposto para identificação de plantas de milho atacadas pela lagarta do cartucho, o resultado final da classificação de um grupo de teste constituído por 90 imagens mostrou que os quatro valores do número de objetos utilizados como limiar, que promoveram os menores erros de classificação, foram 8, 9, 10 e 11.

O resultado da classificação de 720 imagens de plantas atacadas e não atacadas, utilizando-se os quatro valores como limiar, mostrou que o valor mais baixo privilegiou a classificação das plantas atacadas, enquanto o valor mais alto privilegiou a classificação das

plantas não atacadas. O melhor resultado foi obtido pelo algoritmo utilizando 10 objetos como limiar, com erro de classificação de 5,28%.

O algoritmo proposto promoveu maior erro de classificação nas plantas não atacadas, especialmente nos estádios mais avançados de desenvolvimento. O erro de classificação de plantas atacadas ocorreu, principalmente, nos primeiros estádios de desenvolvimento.

Para continuidade do desenvolvimento do sistema de visão artificial, para identificação de plantas de milho atacadas pela lagarta do cartucho, sugerimos para futuros trabalhos: avaliação do algoritmo proposto, utilizando-se imagens de plantas obtidas sob condições de iluminação natural; avaliação de outras câmeras com o objetivo de definir sensores mais baratos para utilização neste sistema; implementação do algoritmo em linguagem compatível com a placa de aquisição de vídeo e sua avaliação quanto ao tempo de processamento; e desenvolvimento da interface entre o algoritmo implementado na placa de aquisição de vídeo e o controlador de um pulverizador.

APÊNDICES

Apêndice A

Código-fonte do algoritmo implementado no MATLAB, para processamento das imagens utilizando o índice do excesso de verde normalizado

```
% m.file utilizado para ler as imagens coloridas originais, processar utilizando
% o indice do excesso de verde normalizado e salvar as imagens monocromaticas
%
% Darly G. Sena Jr. - set/2001
% lab. de projeto de maquinas e visao artificial
% DEA - UFV
%
% Cria o nome da imagem e o caminho
for d=1:9
    if d==1
        data='0719';
    elseif d==2
        data='0720';
    elseif d==3
        data='0721';
    elseif d==4
        data='0722';
    elseif d==5
        data='0723';
    elseif d==6
        data='0724';
    elseif d==7
        data='0725';
    elseif d==8
        data='0726';
    elseif d==9
        data='0727';
    end
    for s=1:30
        for l=2:4
            if s < 10
                imagem=strcat('d:\spodoptera\',data,'\ ',data,'s0',num2str(s),'i',
                    num2str(l),' - RGB.tif');
            else
                imagem=strcat('d:\spodoptera\',data,'\ ',data,'s',num2str(s),'i',
                    num2str(l),' - RGB.tif');
            end
        end
    end
% le a imagem
    fid=imread(imagem);
% elimina as primeiras e ultimas 10 colunas e linhas da imagem
    fid=fid(10:1028,10:1381,:);
% calcula o 2g-r-b
    g=double(fid(:,:,2));
    r=double(fid(:,:,1));
    b=double(fid(:,:,3));
    planta=(2.*g-r-b)./(r+g+b);
% expande para 0 a 255
    pl255=uint8(((planta-min(min(planta))).*255)./(max(max(planta))-min(min(planta))));
% salva a imagem processada
    if s < 10
        salva=strcat('c:\ufv\spodoptera\',data,'s0',num2str(s),'i',num2str(l),'-2grb.tif');
    else
        salva=strcat('c:\ufv\spodoptera\',data,'s',num2str(s),'i',num2str(l),'-2grb.tif');
    end
    imwrite(pl255,salva);
    disp(salva);
end
end
end
```

Apêndice B

Código-fonte do algoritmo implementado no MATLAB, para obtenção dos valores dos limiares manuais

```
% le as imagens coloridas originais, realiza uma primeira limiarizacao com valor baixo,
% apresenta as duas imagens para a pessoa que pode aumentar ou diminuir o limiar
% sem acesso ao valor numerico.
% quando a limiarizacao e considerada satisfatoria, sao salvos o nome da imagem,
% o valor do limiar e o numero de pixels atribuidos a cada classe.
%
% Darly G. Sena Jr. - set/2001
% lab. de projeto de maquinas e visao artificial
% DEA - UFV
%
function f=repet(ima,orig,fad)
% realiza a primeira binarizacao
    t=100;
    bin2=im2bw(ima,t/255);
% limiariza ate criar imagem binaria satisfatoria
    tabom='s';
    while tabom=='s'
        bin2=im2bw(ima,t/255);
        figure(1)
        subplot(2,1,1),imshow(orig);
        subplot(2,1,2),imshow(bin2);
        tabom=input('testar novo limiar? ','s');
        if tabom~='s'|tabom~='n'
            while tabom~='s' & tabom~='n'
                disp('resposta errada!!!!');
                tabom=input('testar novo limiar? ','s');
            end
        end
        if tabom=='s'
            novo=input('aumentar (a) ou diminuir (d)? ','s');
            passo='p';
            pa=input('passo grande (s/n)? ','s');
            if pa=='s'
                if novo=='a'
                    t=t+10;
                elseif novo=='d'
                    t=t-10;
                end
            elseif pa=='n'
                if novo=='a'
                    t=t+1;
                elseif novo=='d'
                    t=t-1;
                end
            end
        end
    end
    end
% calcula o numero de pixels em cada classe
    np1=sum(sum(bin2));
    [lin col]=size(bin2);
    np2=lin*col-np1;
% salva os resultados
    fod=fopen('lim_fulano.txt','a');
    escreve=[t np1 np2];
    fprintf(fod,'%s\t%i\t%i\t%i\n',fad,escreve);
    fclose(fod);
```

Apêndice C

Código-fonte do algoritmo implementado no MATLAB, para obtenção das imagens binárias utilizando o algoritmo iterativo

```
% m.file para ler as imagens coloridas originais, criar as imagens
% binarias utilizando o algoritmo iterativo (Yang, 2001)
%
% Darly G. Sena Jr. - set/2001
% lab. de projeto de maquinas e visao artificial
% DEA - UFV
%
% criar o nome do arquivo e caminho
for d=1:9
    if d==1
        data='0719';
    elseif d==2
        data='0720';
    elseif d==3
        data='0721';
    elseif d==4
        data='0722';
    elseif d==5
        data='0723';
    elseif d==6
        data='0724';
    elseif d==7
        data='0725';
    elseif d==8
        data='0726';
    elseif d==9
        data='0727';
    end
    for s=1:30
        for l=2:4
            if s < 10
                imagem=strcat('c:\ufv\spodoptera\',data,'s0',num2str(s),'i',
                    num2str(l),'-2grb.tif');
                fad=strcat(data,'s0',num2str(s),'i',num2str(l),'-2grb');
            else
                imagem=strcat('c:\ufv\spodoptera\',data,'s',num2str(s),'i',
                    num2str(l),'-2grb.tif');
                fad=strcat(data,'s',num2str(s),'i',num2str(l),'-2grb');
            end
        end
    end
% le a imagem
    fid=imread(imagem);
% acha o limiar automatico iterativamente
    [np,i]=imhist(fid);
    t=(max(i));
    mi=0;
    shclt=0;
    shcll=0;
    for j=0:t
        shclt=shclt+np(j+1);
    end
    while mi<=t & mi<=max(i) | shcll<shclt*0.1;
        scll=0;
        scl2=0;
        shcll=0;
        shcl2=0;
        for j=0:mi
            scll=scll+i(j+1)*np(j+1);
            shcll=shcll+np(j+1);
        end
        for k=mi+1:max(i)
            scl2=scl2+i(k+1)*np(k+1);
            shcl2=shcl2+np(k+1);
        end
        t=round((scll/shcll+scl2/shcl2)/2);
        mi=mi+1;
    end
% realiza a binarizacao
    bin2=im2bw(fid,t/255);
% calcula o numero de pixels atribuidos a cada classe
```

```
        np2=sum(sum(bin2));
        [lin col]=size(bin2);
        np1=lin*col-np2;
% salva os resultados
        fod=fopen('lim_itera.txt','a');
        escreve=[t np1 np2];
        fprintf(fod,'%s\t%i\t%i\t%i\n',fad,escreve);
        fclose(fod);
    end
end
end
```

Apêndice D

Código-fonte do algoritmo implementado no MATLAB, para obtenção das imagens binárias utilizando o algoritmo bayesiano

```
% Programa para cálculo de limiar ótimo por Bayes, para imagem Bimodal
% Autor: Joseph kalil Khoury junior 38924846
% lab. de projeto de maquinas e visao artificial
% DEA - UFV
clear
% cria nome da imagem e caminho
data=input('qual a data? ','s');
for s=1:30
    if s==1
        imagem=strcat('c:\ufv\spodoptera\',data,'s14i2','-2grb.tif');
        fad=strcat(data,'s14i2','-2grb');
    elseif s==2
        imagem=strcat('c:\ufv\spodoptera\',data,'s10i3','-2grb.tif');
        fad=strcat(data,'s10i3','-2grb');
    elseif s==3
        imagem=strcat('c:\ufv\spodoptera\',data,'s08i4','-2grb.tif');
        fad=strcat(data,'s08i4','-2grb');
    elseif s==4
        imagem=strcat('c:\ufv\spodoptera\',data,'s26i2','-2grb.tif');
        fad=strcat(data,'s26i2','-2grb');
    elseif s==5
        imagem=strcat('c:\ufv\spodoptera\',data,'s25i3','-2grb.tif');
        fad=strcat(data,'s25i3','-2grb');
    elseif s==6
        imagem=strcat('c:\ufv\spodoptera\',data,'s17i4','-2grb.tif');
        fad=strcat(data,'s17i4','-2grb');
    elseif s==7
        imagem=strcat('c:\ufv\spodoptera\',data,'s02i2','-2grb.tif');
        fad=strcat(data,'s02i2','-2grb');
    elseif s==8
        imagem=strcat('c:\ufv\spodoptera\',data,'s03i3','-2grb.tif');
        fad=strcat(data,'s03i3','-2grb');
    elseif s==9
        imagem=strcat('c:\ufv\spodoptera\',data,'s15i4','-2grb.tif');
        fad=strcat(data,'s15i4','-2grb');
    elseif s==10
        imagem=strcat('c:\ufv\spodoptera\',data,'s21i2','-2grb.tif');
        fad=strcat(data,'s21i2','-2grb');
    elseif s==11
        imagem=strcat('c:\ufv\spodoptera\',data,'s29i3','-2grb.tif');
        fad=strcat(data,'s29i3','-2grb');
    elseif s==12
        imagem=strcat('c:\ufv\spodoptera\',data,'s28i4','-2grb.tif');
        fad=strcat(data,'s28i4','-2grb');
    elseif s==13
        imagem=strcat('c:\ufv\spodoptera\',data,'s09i2','-2grb.tif');
        fad=strcat(data,'s09i2','-2grb');
    elseif s==14
        imagem=strcat('c:\ufv\spodoptera\',data,'s12i3','-2grb.tif');
        fad=strcat(data,'s12i3','-2grb');
    elseif s==15
        imagem=strcat('c:\ufv\spodoptera\',data,'s04i4','-2grb.tif');
        fad=strcat(data,'s04i4','-2grb');
    elseif s==16
        imagem=strcat('c:\ufv\spodoptera\',data,'s20i2','-2grb.tif');
        fad=strcat(data,'s20i2','-2grb');
    elseif s==17
        imagem=strcat('c:\ufv\spodoptera\',data,'s24i3','-2grb.tif');
        fad=strcat(data,'s24i3','-2grb');
    elseif s==18
        imagem=strcat('c:\ufv\spodoptera\',data,'s23i4','-2grb.tif');
        fad=strcat(data,'s23i4','-2grb');
    elseif s==19
        imagem=strcat('c:\ufv\spodoptera\',data,'s11i2','-2grb.tif');
        fad=strcat(data,'s11i2','-2grb');
    elseif s==20
        imagem=strcat('c:\ufv\spodoptera\',data,'s01i3','-2grb.tif');
        fad=strcat(data,'s01i3','-2grb');
```

```

elseif s==21
    imagem=strcat('c:\ufv\spodoptera\',data,'s13i4','-2grb.tif');
    fad=strcat(data,'s13i4','-2grb');
elseif s==22
    imagem=strcat('c:\ufv\spodoptera\',data,'s18i2','-2grb.tif');
    fad=strcat(data,'s18i2','-2grb');
elseif s==23
    imagem=strcat('c:\ufv\spodoptera\',data,'s22i3','-2grb.tif');
    fad=strcat(data,'s22i3','-2grb');
elseif s==24
    imagem=strcat('c:\ufv\spodoptera\',data,'s27i4','-2grb.tif');
    fad=strcat(data,'s27i4','-2grb');
elseif s==25
    imagem=strcat('c:\ufv\spodoptera\',data,'s07i2','-2grb.tif');
    fad=strcat(data,'s07i2','-2grb');
elseif s==26
    imagem=strcat('c:\ufv\spodoptera\',data,'s05i3','-2grb.tif');
    fad=strcat(data,'s05i3','-2grb');
elseif s==27
    imagem=strcat('c:\ufv\spodoptera\',data,'s06i4','-2grb.tif');
    fad=strcat(data,'s06i4','-2grb');
elseif s==28
    imagem=strcat('c:\ufv\spodoptera\',data,'s16i2','-2grb.tif');
    fad=strcat(data,'s16i2','-2grb');
elseif s==29
    imagem=strcat('c:\ufv\spodoptera\',data,'s19i3','-2grb.tif');
    fad=strcat(data,'s19i3','-2grb');
elseif s==30
    imagem=strcat('c:\ufv\spodoptera\',data,'s30i4','-2grb.tif');
    fad=strcat(data,'s30i4','-2grb');
end
im=imread(imagem);
% numero de classes de tons de cinza
nc=255;
nin=nc;
% probabilidade a priori da classe 1
p1 = .5;
% tamanho da imagem
[L C tipo]=size(im);
imi=im;
nc=nin;
% h= vetor de densidade dos tons de cinza, z=vetor de tons de cinza
[h z]=imhist(im,nc);
hz=h/sum(h);
%algoritmo iterativo para dividir os histogramas para estimar x0 (chute inicial)
titer=max(z); %maximo de iteracoes
ix=1; %indice de z para caminhar no hist
shc11=0;
shclt=sum(hz);
while z(ix)<=titer & ix<=size(z,1)-1 | shc11<shclt*0.2;
    scl1=0;
    scl2=0;
    shc11=0;
    shc12=0;
    for j=1:ix
        scl1=scl1+z(j)*hz(j);
        shc11=shc11+hz(j);
    end

    for k=ix+1:size(z,1)
        scl2=scl2+z(k)*hz(k);
        shc12=shc12+hz(k);
    end
    titer=round((scl1/shc11+scl2/shc12)/2); % z(i) onde (mean(c11)+mean(c12))/2
    ix=ix+1;
end
%chute inicial para metodo do gradiente
%classe 1
z1=z(1:titer);
h1=h(1:titer);
m1=scl1/shc11;
sqd1=(h1'*(z1.^2))-((h1'*z1)^2)/sum(h1);
s1=sqrt(sqd1/(sum(h1)-1));
%classe 2
z2=z(titer+1:nc);
h2=h(titer+1:nc);
m2=scl2/shc12;

```

```

sqd2=(h2'*(z2.^2))-((h2'*z2)^2)/sum(h2);
s2=sqrt(sqd2/(sum(h2)-1));
%soma do erro quadrado (eii) de p(z) de h(z) do chute inicial
eii=0;
for i=1:nc
    eii=eii+(p1/(sqrt(2*pi)*s1)*exp(-(z(i)-m1)^2/(2*s1^2)))+(1-p1)/(sqrt(2*pi)*s2)
        *exp(-(z(i)-m2)^2/(2*s2^2))-hz(i))^2;
end
eip=eii;
% início das iterações pelo método do gradiente
while iter < 100 & max(abs(grad))> 1e-6
%derivada parcial d(ei)/d(m1)
    i=0;
    dml=0;
    repete=0;
    for i=1:nc
        repete=(p1/(sqrt(2*pi)*s1)*exp(-(z(i)-m1)^2/(2*s1^2)))+(1-
p1)/(sqrt(2*pi)*s2)*exp(-(z(i)-m2)^2/(2*s2^2))-hz(i);
        aml= p1*(z(i)-m1) / (sqrt(2*pi)*s1^3) * exp( -( z(i)-m1 )/(2*s1^2) );
        dml=dml+repete*aml;
    end
    dml=2*dml;
%derivada parcial d(ei)/d(m2)
    i=0;
    dm2=0;
    repete=0;
    for i=1:nc
        repete=(p1/(sqrt(2*pi)*s1)*exp(-(z(i)-m1)^2/(2*s1^2)))+(1-p1)/(sqrt(2*pi)*s2)
            *exp(-(z(i)-m2)^2/(2*s2^2))-hz(i);
        am2=( (1-p1)*(z(i)-m2) ) / ( sqrt(2*pi)*s2^3) * exp( -(z(i)-m2)/(2*s2^2) );
        dm2=dm2+repete*am2;
    end
    dm2=2*dm2;
%derivada parcial d(ei)/d(s1)
    i=0;
    ds1=0;
    repete=0;
    for i=1:nc
        repete=(p1/(sqrt(2*pi)*s1)*exp(-(z(i)-m1)^2/(2*s1^2)))+(1-p1)/(sqrt(2*pi)*s2)
            *exp(-(z(i)-m2)^2/(2*s2^2))-hz(i);
        as1=-p1/(sqrt(2*pi)*s1^2)*exp(-(z(i)-m1)^2/(2*s1^2));
        as2=p1/(sqrt(2*pi)*s1^5)*(z(i)-m1)^2*exp(-(z(i)-m1)^2/(2*s1^2));
        ds1=ds1+repete*(as1+as2);
    end
    ds1=2*ds1;
%derivada parcial d(ei)/d(s2)
    i=0;
    ds2=0;
    repete=0;
    for i=1:nc
        repete=(p1/(sqrt(2*pi)*s1)*exp(-(z(i)-m1)^2/(2*s1^2)))+(1-p1)/(sqrt(2*pi)*s2)
            *exp(-(z(i)-m2)^2/(2*s2^2))-hz(i);
        as2= -(1-p1)/(sqrt(2*pi)*s2^2)*exp(-(z(i)-m2)^2/(2*s2^2));
        bs2= (1-p1)/(sqrt(2*pi)*s2^5)*(z(i)-m2)^2*exp(-(z(i)-m2)^2/(2*s2^2));
        ds2=ds2+repete*(as2+bs2);
    end
    ds2=2*ds2;
%derivada parcial d(ei)/d(p1)
    dp1=0;
    repete=0;
    for i=1:nc
        repete=(p1/(sqrt(2*pi)*s1)*exp(-(z(i)-m1)^2/(2*s1^2)))+(1-p1)/(sqrt(2*pi)*s2)
            *exp(-(z(i)-m2)^2/(2*s2^2))-hz(i);
        dp1=dp1+repete*(1/(sqrt(2*pi)*s1)*exp(-(z(i)-m1)^2/(2*s1^2))-1/(sqrt(2*pi)*s2)
            *exp(-(z(i)-m2)^2/(2*s2^2)));
    end
    dp1=2*dp1;
%vetor gradiente
dei=[dml;dm2;ds1;ds2;dp1];
%norma do vetor gradiente
ndei=sqrt(sum(dei.^2));
%gradiente
grad=k*dei/ndei;
%incremento em x
x = x - grad;
% variaveis do vetor x
m1=x(1);

```

```

m2=x(2);
s1=x(3);
s2=x(4);
p1=x(5);
%cálculo do somatório do erro quadrado para cada iteração
ei=0;
for i=1:nc
    ei=ei+((p1/(sqrt(2*pi))*s1)*exp(-(z(i)-m1)^2/(2*s1^2)))+((1-p1)/(sqrt(2*pi)
        *s2)*exp(-(z(i)-m2)^2/(2*s2^2)))- hz(i))^2;
end
%matriz de erro
mei(1,1)=ei;
mei(iter+2,1)=ei;
mei(1,2)=0;
mei(iter+2,2)=iter+1;
% Rotina de k
if ei <= eip
    k=k;
end
if ei > eip
    k=k*0.1;
end
eip=ei;
iter=iter+1;
end
%fim das iteracoes do metodo do gradiente
%cálculo do limiar ótimo (a)*t^2 + (b)*t + c = 0
a=s1^2-s2^2;
b=2*(m1*s2^2-m2*s1^2);
c=s1^2*m2^2-s2^2*m1^2+2*s1^2*s2^2*log((s2*p1)/(s1*(1-p1)));
coef=[a b c];
ti=roots(coef);
tr=ti;
if tr(1,1) < m1 | tr(1,1) > m2
    tr(1,1)=257;
end
if tr(2,1) < m1 | tr(2,1) > m2
    tr(2,1)=257;
end
t=min(tr);
clear iter h z nc k
% cria imagem binaria
bin=im2bw(im,t/255);
np2=sum(sum(bin));
[lin col]=size(bin);
npl=lin*col-np2;
% salva resultados
fod=fopen('lim_bayes.txt','a');
escreve=[t npl np2];
fprintf(fod,'%s\t %i\t %i\t %i\n',fad,escreve);
fclose(fod);
end

```

Apêndice E

Código-fonte do algoritmo implementado no MATLAB, para obtenção das imagens-diferença entre as imagens binárias dos limiares manuais e as imagens binárias dos limiares automáticos

```
% m.file utilizado para criar a imagem diferenca entre a imagem binaria manual e as imagens
% binarias automaticas (iterativo/bayes) e calcular a exatidao global e os erros de omissao
% Darly G. Sena Jr. - set/2001
% lab. de projeto de maquinas e visao artificial
% DEA - UFV
clear
% busca o arquivo com as imagens a serem apresentadas
leu=xlsread('vai_limiar_t');
% cria o nome e caminho das imagens
i=1;
for i=1:90
    if leu(i,2)<10
        imagem=strcat('c:\ufv\spodoptera\', '0', num2str(leu(i,1)), 's0', num2str(leu(i,2)), 'i',
            num2str(leu(i,3)), '-2grb.tif');
        titulo=strcat('0', num2str(leu(i,1)), 's0', num2str(leu(i,2)), 'i',
            num2str(leu(i,3)), '-2grb.tif');
        fad=strcat('0', num2str(leu(i,1)), 's0', num2str(leu(i,2)), 'i',
            num2str(leu(i,3)));
    elseif leu(i,2)>=10
        imagem=strcat('c:\ufv\spodoptera\', '0', num2str(leu(i,1)), 's', num2str(leu(i,2)), 'i',
            num2str(leu(i,3)), '-2grb.tif');
        titulo=strcat('0', num2str(leu(i,1)), 's', num2str(leu(i,2)), 'i', num2str(leu(i,3)),
            '-2grb.tif');
        fad=strcat('0', num2str(leu(i,1)), 's', num2str(leu(i,2)), 'i', num2str(leu(i,3)));
    end
    ima=imread(imagem);
% acessa os valores dos limiares
    man=leu(i,4);
    ite=leu(i,5);
    bay=leu(i,6);
% cria as imagens binarias
    bin_man=im2bw(ima, man/255);
    bin_bay=im2bw(ima, bay/255);
    bin_ite=im2bw(ima, ite/255);
% calcula a imagem diferenca
    dif_bay=logical(abs(double(bin_man)-double(bin_bay)));
    dif_ite=logical(abs(double(bin_man)-double(bin_ite)));
% mudar aqui iterativo ou bayes!!
    dif=dif_bay;
    aut=bin_bay;
% inversao das imagens binarias
    man_inv=(double(bin_man)+1)-(double(bin_man).*2);
    aut_inv=(double(aut)+1)-(double(aut).*2);
% folha classificada como folha
    folha=sum(sum(double(bin_man).*double(aut)));
% fundo classificada como fundo
    fundo=sum(sum(man_inv.*aut_inv));
% folha classificada como fundo
    fol_fun=sum(sum((dif+1).*dif*0.5));
% fundo classificada como folha
    fun_fol=sum(sum((dif-1).*dif*0.5));
%total
    tot=folha+fundo+fol_fun+fun_fol;
% montar matriz de contingencia.
    eo_fol=fol_fun/tot*100;
    eo_fun=fun_fol/tot*100;
    eg=(folha+fundo)/tot*100;
% mostra o resultado
    disp(fad);
    disp(eg);
% salva o resultado
    fod=fopen('res_eg_bayes.txt', 'a');
    escreve=[eg eo_fol eo_fun];
    fprintf(fod, '%s\t %6.4f\t %6.4f\t %6.4f\n', fad, escreve);
    fclose(fod);
end
```

Apêndice F

Código-fonte do algoritmo implementado no MATLAB, para classificação das imagens de acordo com o número de objetos em blocos das imagens

```
% m.file utilizado para classificar as imagens de acordo com
% o numero de objetos nos blocos 300x300
%
% Darly G. Sena Jr. - set/2001
% lab. de projeto de maquinas e visao artificial
% DEA - UFV
%
clear
%
dt=[720 721 722 723 724 725 726 727];
bl=300;
ea8=0;
ea9=0;
ea10=0;
eall=0;
ena8=0;
ena9=0;
enal0=0;
enall=0;
% busca o arquivo com os dados
leu=xlsread('vai_limiar_t');
c=1;
bl=300;
% Cria o nome da imagem e o caminho
while c<91
    if leu(c,2)<10
        imagem=strcat('c:\ufv\spodoptera\', '0', num2str(leu(c,1)), 's0', num2str(leu(c,2)),
            'i', num2str(leu(c,3)), '-2grb.tif');
        fad=strcat('0', num2str(leu(c,1)), 's0', num2str(leu(c,2)), 'i', num2str(leu(c,3)));
    elseif leu(c,2)>=10
        imagem=strcat('c:\ufv\spodoptera\', '0', num2str(leu(c,1)), 's', num2str(leu(c,2)),
            'i', num2str(leu(c,3)), '-2grb.tif');
        fad=strcat('0', num2str(leu(c,1)), 's', num2str(leu(c,2)), 'i', num2str(leu(c,3)));
    end
    ima=imread(imagem);
    ite=leu(c,5);
    bin_ite=logical(abs(double(im2bw(ima, ite/255))-1));
    bin_itef=medfilt2(bin_ite);
% ajusta linhas e colunas para multiplo do bloco
    [lin col ma]=size(ima);
    lin_aj=fix(lin/bl)*bl;
    lin_ini=fix((lin-lin_aj)/2);
    col_aj=fix(col/bl)*bl;
    col_ini=fix((col-col_aj)/2);
    a=lin_aj/bl-1;
    b=col_aj/bl-1;
    pl8=0;
    pl9=0;
    pl10=0;
    pl11=0;
    c8=0;
    c9=0;
    c10=0;
    c11=0;
% cria os blocos
    for i=0:a
        for j=0:b
% pega o bloco marcado
            ambw=bin_itef(i*bl+lin_ini+1:i*bl+lin_ini+bl, j*bl+col_ini+1:j*bl+col_ini+bl);
            total=sum(sum(ambw));
% testa a % de folha
            if total < 85500
                obj=bwlabel(ambw);
                nobj=max(max(obj));
% classifica de acordo com o numero de objetos
                if nobj<8
                    se8=0;
                    se9=0;
                    se10=0;
```

```

        sell=0;
    elseif nobj==8
        se8=1;
        se9=0;
        sel0=0;
        sell=0;
        pl8=1;
    elseif nobj==9
        se8=1;
        se9=1;
        sel0=0;
        sell=0;
        pl8=1;
        pl9=1;
    elseif nobj==10
        se8=1;
        se9=1;
        sel0=1;
        sell=0;
        pl8=1;
        pl9=1;
        pl10=1;
    elseif nobj>10
        se8=1;
        se9=1;
        sel0=1;
        sell=1;
        pl8=1;
        pl9=1;
        pl10=1;
        pl11=1;
    end
    if c8==0 & pl8==1
        c8=1;
    elseif c9==0 & pl9==1
        c9=1;
    elseif c10==0 & pl10==1
        c10=1;
    elseif c11==0 & pl11==1
        c11=1;
    end
% salva o resultado dos blocos
    escreve=[i+1 j+1 nobj se8 se9 sel0 sell];
    fod=fopen('result_bl.txt','a');
    fprintf(fod,'%s\t %2f\t %2f\t %6f\t %2f\t %2f\t %2f\t %2f\n',fad,escreve);
    fclose(fod);
end
end
end
% classifica a imagem, se pelo menos um bloco foi classificado como atacado
if leu(c,2)<16 & c8==0
    ea8=ea8+1;
end
if leu(c,2)<16 & c9==0
    ea9=ea9+1;
end
if leu(c,2)<16 & c10==0
    ea10=ea10+1;
end
if leu(c,2)<16 & c11==0
    ea11=ea11+1;
end
if leu(c,2)>=16 & c8==1
    ena8=ena8+1;
end
if leu(c,2)>=16 & c9==1
    ena9=ena9+1;
end
if leu(c,2)>=16 & c10==1
    ena10=ena10+1;
end
if leu(c,2)>=16 & c11==1
    ena11=ena11+1;
end
escreve2=[ea8 ea9 ea10 ea11 ena8 ena9 ena10 ena11];
% salva o resultado da imagem
    escreve1=[c8 c9 c10 c11];

```

```
    fed=fopen('result_ima.txt','a');
    fprintf(fed,'%s\t %2F\t %2f\t %2f\t %2f\n',fad,escreve1);
    fclose(fed);
    c=c+1;
end
% salva o resultado final da classificacao
escreve2=[ea8 ea9 ea10 ea11 ena8 ena9 ena10 ena11];
fud=fopen('result_final.txt','a');
fprintf(fud,'%6f\t %6f\t %6f\t %6f\t %6f\t %6f\t %6f\t %6f\n',escreve2);
fclose(fud);
```