



Algoritmo para classificação de plantas de milho atacadas pela lagarta do cartucho (*Spodoptera frugiperda*, Smith) em imagens digitais¹



Darly G. de Sena Júnior², Francisco de A. de C. Pinto³, Daniel M. de Queiroz⁴ & Evandro C. Mantovan⁵

¹ Pesquisa financiada pelo Banco Mundial e Embrapa através do Projeto de Apoio ao Desenvolvimento de Tecnologia Agropecuária para o Brasil (PRODETAB Projeto 030-01/99)

² DEA/UFV, CEP 36571-000, Viçosa, MG. Fone: (31) 3899-1881. E-mail: ms19630@correio.ufv.br (Foto)

³ DEA/UFV. Fone: (31) 3899-1881. E-mail: facpinto@ufv.br

⁴ DEA/UFV. Fone: (31) 3899-1882. E-mail: queiroz@ufv.br

⁵ Embrapa Milho e Sorgo. Fone: (31) 3779-1105. E-mail: evandro@cnpmc.embrapa.br

Protocolo 043 - 3/4/2001

Resumo: Foi desenvolvido e testado, no presente estudo, um algoritmo de processamento e análise de imagens digitais para identificação de plantas de milho atacadas pela lagarta do cartucho, o qual consistiu em duas etapas de classificação dos objetos presentes na cena de uma lavoura de milho. Na primeira etapa, denominada classificação grosseira, utilizou-se a técnica de limiarização em blocos da imagem com 60 x 60 pixels de dimensão e, na segunda etapa, denominada classificação refinada, utilizaram-se redes neurais artificiais em blocos com 3 x 3 pixels de dimensão. A exatidão de cada etapa do algoritmo foi acessada através da determinação da matriz de contingência, com base em 80 e 75 blocos, para a classificação grosseira e refinada, respectivamente. O algoritmo apresentou índice de exatidão global de 80,74%.

Palavras-chave: visão artificial, agricultura de precisão, redes neurais artificiais

Algorithm for classification of fall armyworm (*Spodoptera frugiperda*, Smith) damaged corn plants on digital images

Abstract: An image processing and analysis algorithm was developed to identify the fall armyworm damage on corn plants. The developed program segmented the larvae damage on the image in two stages: a coarse and fine classification. The coarse stage applied a threshold technique on image blocks of 60 x 60 pixels. The fine stage was based on a neural network classifier which classifies image blocks of 3 x 3 pixels. The algorithm accuracy was accessed by evaluating the error matrix based on 80 and 75 image blocks of the coarse and fine stages, respectively. The algorithm presented an overall accuracy of 80.74%.

Key words: machine vision, precision farming, artificial neural networks

INTRODUÇÃO

A agricultura de precisão pode ser considerada como a habilidade em se monitorar e acessar a atividade agrícola em nível local, com o objetivo de aumentar a eficiência do processo produtivo (Queiroz et al., 2000). Com o manejo homogêneo das áreas agrícolas, naturalmente heterogêneas, ocorre a aplicação excessiva de insumos em certas áreas, com desperdício de recursos e maior possibilidades de contaminação ambiental. Por outro lado, nas áreas onde se aplicam subdosagens deixa-se de explorar todo o potencial produtivo da parcela ou, dependendo do defensivo aplicado, pode-se facilitar o surgimento de espécies resistentes.

No manejo integrado de pragas (MIP) utilizam-se estratégias com que se visa monitorar a evolução das pragas, com o objetivo da aplicação de medidas de controle somente

quando a população da praga atinge o nível de dano econômico, ou seja, o custo de controle seja inferior ao dano provocado pela praga. O MIP tem sido trabalhado estimando-se a densidade média de pragas por lavoura ou talhão, mas com o advento da agricultura de precisão abrem-se novas possibilidades de manejo. A expectativa da integração dos conceitos do MIP às técnicas de agricultura de precisão é grande. Allen et al. (1999) afirmam que a união dessas técnicas seria a situação ideal do MIP, cujos defensivos agrícolas são aplicados apenas onde são necessários; além disso, a agricultura de precisão pode auxiliar o MIP, inferindo com base em dados dos anos anteriores as áreas mais sujeitas ao ataque de pragas, áreas sob condições de estresse e quantificando a importância econômica das pragas. Pode identificar, ainda, as partes ecologicamente vulneráveis e ajustar os tratamentos de acordo com essas condições (Daberkow & Christensen, 1996).

Embora parte das tecnologias necessárias esteja disponível, outras ainda necessitam de adaptação a características específicas de cada cultura e suas exigências, pragas, doenças e plantas daninhas, sem se deixar de levar em conta a adaptação às condições econômicas e culturais do país e do produtor agrícola.

A utilização das técnicas de sensoriamento remoto e visão artificial através de imagens de alta resolução obtidas a partir de câmaras instaladas em equipamentos agrícolas, visa eliminar as dificuldades de trabalho com aeronaves possibilitando, até mesmo, a tomada de decisão em tempo real, pelos equipamentos.

Nos sistemas de visão artificial faz-se a integração de uma câmara e um computador com os sinais gerados pela câmara, processados por algoritmos, para extração de uma série de características dos objetos da imagem. Esses sistemas têm diversas vantagens sobre os métodos convencionais de sensoriamento remoto. Como exemplo, citam-se: a integração com outros procedimentos automáticos, a possibilidade de funcionamento em tempo integral, a execução de medições com maior grau de acurácia e consistência que seres humanos, além de medir a cor e a morfologia de objetos de maneira objetiva, ao passo que seres humanos o fazem de maneira subjetiva (Batchelor, citado por Jayas et al., 2000). O desafio da segmentação de uma imagem de um campo agrícola é grande, devido à sua complexidade (Sadjadi, 1996) e ao fato de que os produtos agrícolas apresentam, de modo geral, uma variação muito grande quanto à forma, o tamanho e a cor. Somam-se, ainda, as dificuldades impostas pelo ambiente de trabalho dos equipamentos no campo, onde estão sujeitos a grandes variações de luminosidade e temperatura, além da possibilidade de ocorrências de chuvas e poeira.

Diversos métodos têm sido desenvolvidos para determinação das condições do solo, estado da cultura, detecção de pragas e estresse hídrico, utilizando-se imagens multiespectrais (Barnes et al., 1996). Além disso, sistemas de visão artificial foram utilizados para seleção de produtos agrícolas (Shearer & Payne, 1990; Park & Chen, 1996); identificação de plantas (Guyer et al., 1986, Jia & Krutz, 1992, Pérez et al., 2000, Shearer & Holmes, 1990) e avaliação das condições da cultura (Bacci et al., 1998); no entanto, poucos têm sido os trabalhos publicados onde se utiliza processamento de imagens digitais para identificação e monitoramento do ataque de pragas em culturas. Acredita-se que diversos motivos causam menor interesse pelas pesquisas nessa área, podendo-se citar a dificuldade para quantificação da população de insetos e sua exata localização no campo, devido à sua mobilidade, o que praticamente inviabiliza a utilização de mapas de prescrição, nesses casos.

A lagarta do cartucho (*Spodoptera frugiperda*) é uma praga que ataca, preferencialmente, o cartucho da planta de milho, consumindo grande parte da área foliar antes das folhas se abrirem. A ocorrência do ataque nos primeiros estádios da cultura pode provocar a morte das plantas (Waquil et al., 1982). Cruz & Turpin (1982) avaliaram o ataque dessa praga em milho e observaram perdas de 18,7% quando o ataque ocorreu no estádio de 8 - 10 folhas (40 d após o plantio). Oliveira (1987) observou em parcelas de milho com solo corrigido perdas de 42%, diminuindo com o aumento do teor de alumínio no solo. Carvalho (1987) afirmou que a importância de *S. frugiperda*

como praga da cultura do milho é indiscutível, e que sem dúvida deve ser considerada a praga chave em um programa de manejo integrado. Fancelli & Dourado Neto (2000) consideram a lagarta do cartucho a principal praga da cultura do milho, com o grau de dano variável de acordo com a época de semeadura, clima, estado nutricional da lavoura e estágio fenológico da planta, recomendando para controle, a aplicação de inseticidas específicos, quando se atingir o nível de 20% de folhas raspadas.

No controle da lagarta do cartucho através de equipamentos para aplicação de defensivos a taxas variáveis, pode-se utilizar o sistema com base em mapas, no qual se elabora um mapa da infestação e, a partir deste, um mapa de aplicação, que é utilizado pelo equipamento para aplicar o defensivo somente nas áreas atacadas. Pode-se trabalhar, ainda, em tempo real, no qual um sistema de visão artificial deve utilizar um algoritmo capaz de identificar nas imagens os sintomas do ataque em tempo hábil, de acordo com a velocidade de deslocamento do equipamento no campo, para abrir ou fechar a válvula que controla a saída do produto; além disto, o sistema utilizado para elaboração do mapa de infestação ou para controle da aplicação em tempo real, deve ser pouco sensível às variações das condições de iluminação entre os diversos horários do dia e às sombras presentes em uma mesma imagem.

Uma rede neural artificial (RNA) é uma rede de numerosos elementos computacionais não lineares, altamente interconectados, operando em paralelo e organizados em padrão semelhante a uma rede neural biológica (Lippmann, 1987), e que adquirem conhecimento através da experiência. Uma rede neural de múltiplas camadas com a regra de aprendizado pela retropropagação do erro, é um eficiente sistema para o aprendizado da discriminação de classes, a partir de uma série de exemplos (Jayas et al., 2000).

Uma desvantagem no uso de RNA é o fato da não existência de métodos teóricos disponíveis para definição da estrutura ideal da rede, como o número de camadas ocultas e o número de neurônios, o que controla a capacidade de aprendizado e classificação da rede (Jayas et al., 2000). Outra limitação das redes neurais artificiais é que elas podem ser vistas como “caixas pretas”, na qual quase não se sabe por que a rede chega a determinado resultado. Normalmente, o tempo exigido para treinamento de redes neurais é elevado, podendo alcançar várias horas, em função de fatores como o número de neurônios, o número de amostras e dos parâmetros do algoritmo de treinamento; porém, uma vez criada e adequadamente treinada, o tempo de processamento para classificação é extremamente curto (Mitchell, 1997).

O objetivo deste trabalho foi o desenvolvimento e a avaliação de um método de processamento de imagens digitais de plantas de milho, visando à identificação das plantas com sintomas de ataque pela lagarta do cartucho. Esse método incorpora uma rede neural artificial, de modo a possibilitar um processamento rápido e eficiente, permitindo sua utilização em algoritmos de sistemas de visão artificial.

MATERIAL E MÉTODOS

Com o objetivo de se diminuir o tempo de processamento e a exigência computacional do método, o mesmo foi subdividido em duas etapas, uma fase de classificação de baixa resolução

(grosseira) e outra fase de classificação de alta resolução (refinada). A Figura 1 ilustra as fases utilizadas para o processamento das imagens.

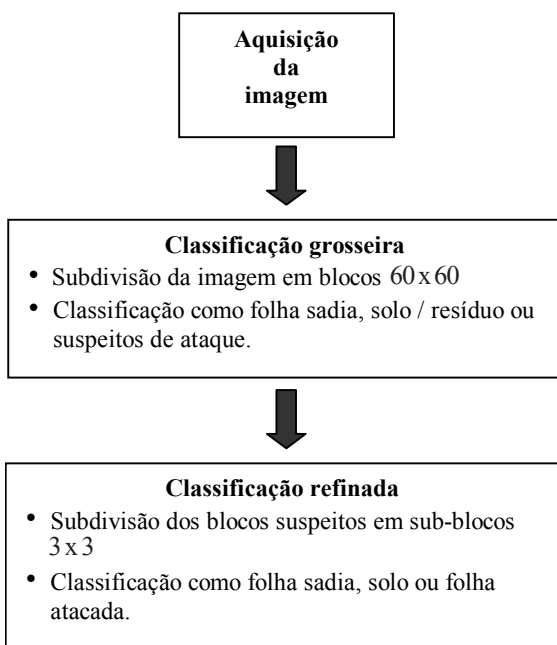


Figura 1. Fases utilizadas no processamento da imagem

Classificação grosseira

Esta fase de classificação foi utilizada com o objetivo de se descartar as porções da imagem com predominância de pixels de solo/resíduo e folhas sadias restringindo, desta forma, o número de pixels examinados na classificação refinada.

Como a imagem original possuía dimensão de 480 linhas e 640 colunas, nesta etapa, foram descartadas 40 colunas de pixels, 20 de cada lado da imagem, para tornar o número de linhas e colunas múltiplo de 60, que foi a dimensão dos blocos utilizados na fase de classificação grosseira.

As folhas fotossinteticamente ativas absorvem intensamente a energia eletromagnética incidente que apresenta comprimentos de onda correspondentes às regiões do vermelho (0,6 a 0,7 μm) e do azul (0,4 a 0,5 μm) enquanto refletem energia na região do verde (0,5 a 0,6 μm). O solo reflete mais a energia compreendida na região do vermelho. Já as porções da folha atacadas pela lagarta (folhas raspadas), devido à sua tonalidade clara, refletem, de forma similar, nas três bandas do visível. O algoritmo proposto extraiu as matrizes da intensidade de vermelho, verde e azul da imagem original e, a partir dessas matrizes procedeu-se ao cálculo do índice do excesso de verde normalizado, para cada pixel da imagem, de acordo com a Eq. 1.

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

em que:

- Evd - excesso de verde normalizado
- Vm - valor do pixel na banda vermelha
- Vd - valor do pixel na banda verde
- Az - valor do pixel na banda azul

Com a normalização, procurou-se diminuir a influência da variação de iluminação e sombras na imagem. O valor calculado desse índice foi utilizado para segmentação dos blocos da imagem nas classes de interesse e, devido à grande reflexão da energia da banda verde pelas folhas sadias, o valor do Evd dos pixels de folhas sadias é mais elevado que o das demais classes (solo, resíduo e folhas raspadas); assim, utilizou-se uma limiarização com o valor do limiar obtido por tentativa-e-erro, para separar a classe de folhas sadias das demais classes.

A imagem foi subdividida em 80 blocos de 60 x 60 elementos; assim, dependendo do valor do Evd, cada pixel do bloco foi classificado como folha sadia ou não. A definição desse limiar para o Evd foi realizada por tentativa-e-erro. Cada bloco foi classificado em solo/resíduo, folha sadia ou suspeita de estar atacada, de acordo com a contagem de pixels classificados como pertencentes a folhas sadias no bloco. Desta maneira, definiu-se um limite superior e outro inferior para esse contador de pixels de folhas sadias. Se o contador não atingisse o limite inferior, o bloco seria classificado como solo/resíduo; acima do limite superior o seria como folha sadia e, entre os dois limites, como suspeito de ataque. As coordenadas de localização dos blocos suspeitos de ataque eram armazenadas para a etapa seguinte de classificação refinada. Os valores dos limites superior e inferior do contador, foram obtidos por tentativa-e-erro.

Classificação refinada

Nessa etapa de classificação, cada bloco suspeito foi subdividido em 400 sub-blocos de 3 x 3 elementos, cada um era classificado por meio de uma rede neural artificial utilizando-se como valor de entrada, o índice da diferença de verde e vermelho normalizada para os nove elementos constituintes do subbloco, calculado de acordo com a Eq. 2.

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

em que:

- Dvv - diferença normalizada do verde e vermelho
- Vm - valor do pixel na banda vermelha
- Vd - valor do pixel na banda verde
- Az - valor do pixel na banda azul

A rede neural fornecia, como resposta, um vetor de 3 elementos, com valores de 0 a 1. Com base nos valores desse vetor, o bloco era classificado como solo, folha sadia ou folha atacada.

Rede neural artificial

Utilizou-se uma rede neural artificial de múltiplas camadas, treinada pelo método da retropropagação do erro. A rede neural utilizada foi do tipo 9-n1-n2-3, isto é, um vetor de entrada com 9 elementos (número de pixels do bloco a ser classificado), n1 e n2 neurônios nas camadas ocultas e 3 neurônios na camada de saída, correspondentes às três classes desejadas (folha atacada, folha sadia e solo). As funções de transferência utilizadas nas redes neurais foram do tipo tangente hiperbólica sigmóide para as camadas ocultas, e do tipo logística sigmóide para a camada

de saída. O neurônio de saída que apresentou o maior valor foi escolhido para atribuir o sub-bloco à classe que o mesmo representava. A Figura 2 ilustra a estrutura da rede neural artificial utilizada para classificação dos sub-blocos 3 x 3 da imagem.

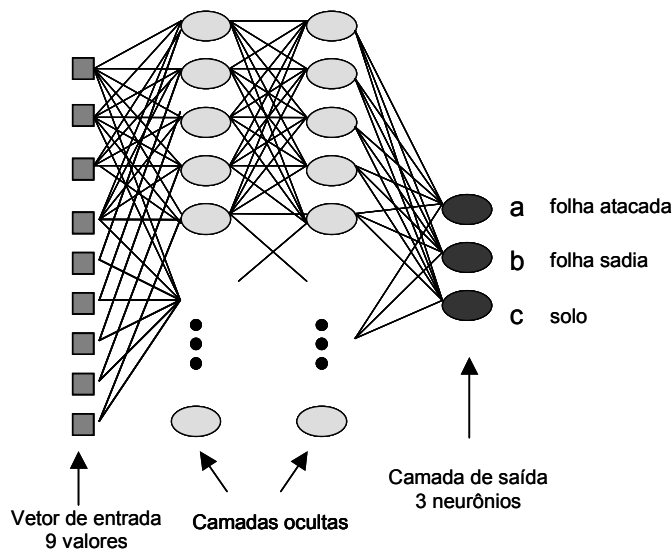


Figura 2. Esquema da estrutura da rede neural artificial

Para seleção da rede neural mais adequada para utilização no algoritmo, foram criados cinco tipos de rede neural artificial, com o número de neurônios (n_1 e n_2) nas camadas ocultas de 20-10, 15-10, 10-8, 8-5 e 5-3. Criaram-se, também, 10 redes de cada tipo com os parâmetros livres inicializados aleatoriamente, escolhendo-se aquela que apresentou o menor erro quadrático médio (EQM) ao final do treinamento. O treinamento de cada rede utilizando-se o gradiente descendente, foi interrompido após 10.000 épocas. Para cada arquitetura proposta escolheu-se a que apresentou o menor EQM ao final do treinamento. Os vetores utilizados para treinamento das redes foram obtidos extraíndo-se 10 amostras de sub-blocos 3 x 3 de cada classe desejada na classificação - solo, folhas saudias e folhas raspadas. Para cada uma das amostras calculou-se o valor do índice da diferença normalizada de verde e vermelho para os nove pixels, de acordo com a Eq. 2. O resultado obtido foi transformado em um vetor e os vetores das 30 amostras, agrupados em uma matriz de amostras.

As cinco redes selecionadas foram avaliadas utilizando-se um outro grupo de amostras, as amostras de teste, coletadas e processadas da mesma forma que as amostras de treinamento. O resultado obtido foi avaliado com relação ao número de amostras classificadas corretamente e à diferença entre o resultado esperado e o obtido. A rede que apresentou o melhor desempenho nesses testes e menor EQM no treinamento foi selecionada para utilização no programa.

Teste do algoritmo

Para teste do algoritmo desenvolvido neste trabalho, utilizou-se uma imagem digital de uma planta de milho, com injúrias provocadas pelo ataque inicial da lagarta do cartucho (*Spodoptera frugiperda*). Esta imagem foi obtida por meio de uma câmara digital colorida Sony Mavica, modelo MVC-FD73, instalada em um tripé com altura de 1,25 m, sobre a

planta a ser imageada, de maneira que a câmara ficasse paralela ao solo. Utilizou-se um zoom de 10 x na máquina, com o objetivo de obter boa resolução espacial. A imagem obtida apresentava 480H x 640V pixels.

A imagem foi processada utilizando-se o algoritmo desenvolvido, avaliando-se a eficiência da classificação nas duas etapas do processamento, na classificação grosseira e na classificação refinada.

Para reportar erros na classificação das imagens, foi utilizada a metodologia proposta por Campbell (1987), na qual se faz uso de uma matriz de erros ou tabela de contingência, identificando-se não somente o erro global da classificação para cada categoria mas, também, entre categorias. De posse dessa matriz, pode-se efetuar o cálculo do índice de exatidão global, de acordo com a Eq. 3.

$$Eg = \frac{Pc}{Pt} \times 100 \quad (3)$$

em que:

- Eg - Índice de exatidão global
- Pc - Número de pixels corretamente classificados
- Pt - Número total de pixels avaliados

A classificação grosseira foi avaliada considerando-se todos os 80 blocos classificados pelo algoritmo. Foi elaborada uma rotina que delimitava, sobre a imagem original, os limites dos blocos que, por sua vez, foram visualmente classificados como predominância de solo, predominância de folha sadia ou suspeita de ataque pela lagarta. Os blocos nos quais a proporção de pixels de solo e folha eram semelhantes, foram classificados como suspeitos de ataque para serem processados na classificação refinada. Elaborou-se a matriz de contingência da classificação grosseira e se procedeu ao cálculo do índice de exatidão global.

A classificação refinada foi avaliada comparando-se a acurácia da classificação em 45 sub-blocos de cada classe (solo, folha sadia e folha raspada) escolhidos previamente na imagem original, dentro dos blocos suspeitos de ataque. Elaborou-se a matriz de contingência e se calculou o índice de exatidão global da classificação desses sub-blocos. A exatidão global do algoritmo foi considerada igual à da classificação refinada, visto que esta é a última etapa de classificação.

RESULTADOS E DISCUSSÃO

Escolha da arquitetura da rede neural artificial

A Tabela 1 apresenta o erro quadrático médio (EQM) obtido para cada rede ao final do treinamento de 10.000 épocas com 10 amostras de cada classe. Verifica-se que a rede neural que apresentou menor EQM, foi a que possuía 15-10 neurônios nas camadas ocultas. O pior resultado foi apresentado pela rede com 8-5 neurônios.

Tabela 1. Erro quadrático médio (EQM) ao final do treinamento, para as redes selecionadas

Arquitetura	5-3	8-5	10-8	15-10	20-10
EQM	0,06	0,17	0,03	0,02	0,03

O EQM não é suficiente para selecionar uma rede neural pois, se houver memorização dos dados do treinamento, o EQM será pequeno ao final do treinamento, mas inaceitável para dados diferentes da amostra de treinamento (Mitchell, 1997).

A Tabela 2 apresenta o resultado do número de amostras identificadas corretamente pelas cinco redes neurais. Esses valores foram obtidos comparando-se os 3 valores de resposta para cada amostra, onde foi verificado se o maior valor foi gerado na linha correspondente à classe da amostra. Verifica-se que somente a rede 8 x 5 não apresentou resultados satisfatórios, não sendo capaz de identificar as amostras de folha. As demais redes apresentaram resultados idênticos, deixando-se de identificar apenas uma amostra de solo, das 10 submetidas às redes; sendo assim, a rede 8-5 foi descartada para uso no programa.

Tabela 2. Número de amostras identificadas corretamente pelas cinco redes neurais

Arquitetura	5-3	8-5	10-8	15-10	20-10
Folha sadia	10	0	10	10	10
Folha raspada	10	10	10	10	10
Solo	9	9	9	9	9

Avaliou-se, ainda, a diferença entre o valor esperado e o valor obtido de saída das redes, quando submetidas às amostras de teste. A Tabela 3 apresenta os valores médios da diferença entre os valores esperados e os obtidos para as três classes e para as cinco redes neurais. Verifica-se, também, que as menores diferenças foram obtidas pelas redes neurais com maior número de neurônios nas camadas ocultas, ou seja, as redes com 20-10 e com 15-10 neurônios, que apresentaram diferença média geral de 0,18.

Tabela 3. Valores médios da diferença entre os valores esperados e obtidos para as três classes e para as cinco redes neurais

Arquitetura	5-3	8-5	10-8	15-10	20-10
Folha sadia	0,04	1,00	0,12	0,07	0,05
Folha raspada	0,47	0,57	0,27	0,26	0,26
Solo	0,31	0,29	0,26	0,21	0,23
Geral	0,27	0,62	0,22	0,18	0,18

Este resultado é coerente com o resultado do EQM das amostras de treinamento, indicando que nas redes com menor número de neurônios o número de conexões não foi suficiente para um bom aprendizado e generalização; sendo assim, selecionaram-se as redes 15-10 e 20-10, para implementação e teste no programa de processamento da imagem.

Classificação grosseira

O valor de excesso de verde normalizado utilizado como limiar na etapa de classificação grosseira, foi de 0,204, obtido por tentativa-e-erro avaliando-se o resultado visualmente. A Figura 3 ilustra as imagens original e binária resultante do processamento, em que foi utilizado o índice do excesso de verde, com limiar de 0,204.

Verifica-se que o índice do excesso de verde normalizado, associado ao limiar de 0,204, foi eficiente para separar os pixels de folhas sadias dos demais constituintes da imagem. As áreas da folha atacadas pela lagarta foram perfeitamente segmentadas

e as sombras presentes na imagem original não influenciaram o resultado da limiarização.

Na classificação dos blocos 60 x 60 foram utilizados os limites inferior e superior de 1800 e 3500, respectivamente, para o contador de pixels de folhas sadias. A Figura 4 apresenta os blocos classificados como suspeitos de ataque (contador entre os dois limites). Esses blocos foram selecionados para a classificação refinada.

Comparando-se a classificação visual e a classificação pelo programa, elaborou-se a matriz de contingência, apresentada na Tabela 4.

Tabela 4. Matriz de contingência da análise grosseira

Imagem Referência	Imagem Classificada				E.O (%)
	Solo	Suspeito	Folha	Total	
Solo	34	0	0	34	0
Suspeito	0	19	4	23	17,4
Folha	0	5	18	23	21,7
Total	34	24	22	80	
E.C. (%)	0	21,7	17,4		

Verifica-se que a classe solo foi a que apresentou melhor classificação, ou seja, sem erros. A classe de blocos suspeitos apresentou 17,4% de erros de omissão (E.O.) e 21,7% de erros de comissão (E.C.), onde blocos de folhas foram classificados como suspeitos. Uma vez que a classe solo não apresentou erros, os erros de comissão da classe folhas foi de 17,4%, representados por blocos suspeitos classificados como folhas. O erro de omissão na classe de blocos suspeitos é mais grave que o erro de comissão, pois esses blocos serão processados novamente na etapa de classificação refinada e, na segunda etapa, este erro pode ser corrigido aumentando-se porém, o número de sub-blocos processados. Por outro lado, classificando-se um bloco suspeito como folha sadia, pode-se impedir que o programa identifique uma planta com sintomas de ataque pela lagarta do cartucho.

A partir dos dados da matriz de contingência, procedeu-se ao cálculo do índice de exatidão global (Eg), obtendo-se o valor de 88,75%. O resultado geral da classificação grosseira foi considerado satisfatório, pois se conseguiu atingir o objetivo de diminuir o número de pixels a serem processados na fase de classificação refinada. A partir de uma imagem original de 307.200 pixels, selecionaram-se 25 blocos, constituídos por 90.000 pixels. O descarte de 217.200 pixels, que deixaram de ser processados na classificação refinada, proporcionou maior rapidez e eficiência do programa de processamento, uma vez que a fase de classificação refinada é mais lenta e mais exigente nos aspectos computacionais.

Classificação refinada

Aqui foram utilizadas as redes neurais com 15-10 e com 20-10 neurônios nas camadas ocultas, selecionadas de acordo com os erros de treinamento e teste. A comparação visual do resultado da classificação pelas redes neurais 15-10 e 20-10, mostrou que as imagens geradas eram muito semelhantes.

As matrizes de contingência das duas imagens classificadas, elaboradas para os 135 sub-blocos selecionados na imagem original, foram idênticas. A Tabela 5 apresenta a matriz de contingência para as imagens geradas pela análise refinada,




Figura 3. Imagens original (A) e binária (B) resultantes do processamento, em que foi utilizado o índice do excesso de verde normalizado, com limiar de 0,204



Figura 4. Blocos selecionados para processamento com a rede neural

utilizando-se as redes neurais com 15-10 e 20-10 neurônios nas camadas ocultas, quando comparadas com a imagem original.

Constata-se que a classe de folhas saudias foi classificada sem erros de omissão, indicando que, para esta classe, o programa foi altamente eficiente apresentando, no entanto, 35,6% de erros de comissão para as amostras selecionadas.

Tabela 5. Matriz de contingência da análise refinada, utilizando-se as redes neurais com 15-10 e 20-10 neurônios nas camadas ocultas

Imagem de Referência	Imagem Classificada				
	F. Sadia	F. Raspada	Solo	Total	E.O (%)
Folha sadia	45	0	0	45	0
Folha raspada	7	38	0	45	15,6
Solo	9	10	26	45	42,2
Total	61	48	26	135	
E.C. (%)	35,6	22,2	0		

A classe de folhas atacadas (raspadas) apresentou erros de omissão de 15,6% e erros de comissão de 22,2%. Seria desejável que os erros de comissão fossem ainda menores, pois se reduziriam os riscos de plantas saudias serem classificadas como atacadas. O valor baixo do erro de omissão comprova a capacidade das redes neurais de identificar os sub-blocos de folhas atacadas. O maior problema da classificação refinada foi em relação à classe solo, que apresentou exclusivamente erros de omissão, com 42,2%, ou seja, os pixels de solo foram classificados como folhas saudias ou folhas raspadas, mas pixels de outras classes não foram classificados como solo. Esses erros são uma consequência da heterogeneidade dessa classe, que engloba o solo propriamente dito e resíduos na superfície.

O índice de exatidão global, calculado para a amostragem realizada nas imagens geradas pela classificação refinada, apresentou valor de 80,74%, embora influenciado pela classificação eficiente das folhas, em detrimento do resultado da classe solo.

As Figuras 5A e 5B ilustram, respectivamente, as imagens geradas pela classificação, utilizando-se a rede neural com

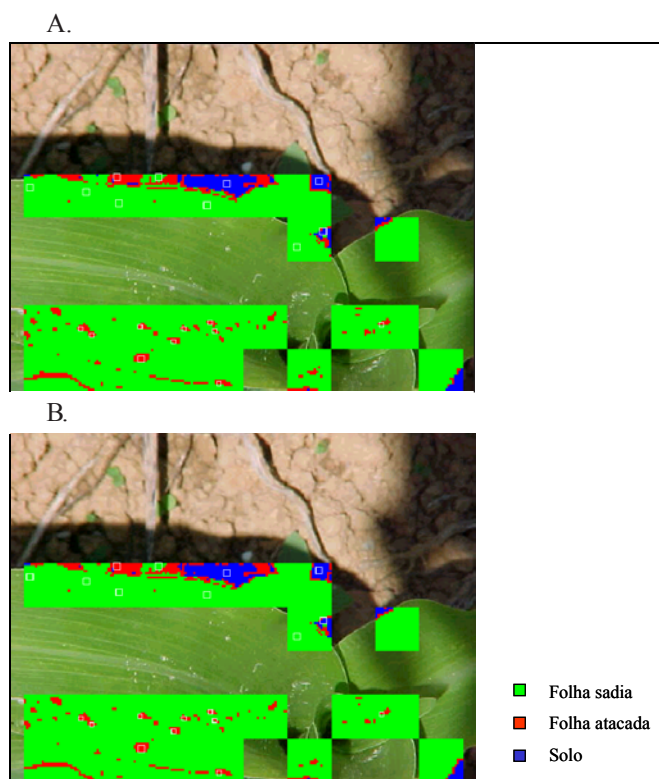


Figura 5. Imagens geradas pela classificação, utilizando-se a rede neural com 15-10 (A) e 20-10 (B) neurônios nas camadas ocultas, respectivamente

15-10 e com 20-10 neurônios nas camadas ocultas. Nas duas imagens são circundados em branco os blocos de amostras selecionados para avaliação do resultado final da classificação refinada.

Verifica-se que a classificação pelas duas redes foi muito semelhante e, também, que a classificação dos pixels de folhas saudáveis foi excelente, mesmo nas porções sombreadas da imagem, ou nas folhas das plantas daninhas; até mesmo as nervuras, de verde um pouco mais claro, foram classificadas corretamente como folhas saudáveis, ocorrendo erros apenas nas bordas das folhas.

O resultado na classe de folhas atacadas não foi o ideal, pois o programa classificou as bordas das folhas e outras porções da imagem de tonalidades claras como folhas atacadas, porém, é importante observar que o programa praticamente não omitiu nenhum bloco realmente atacado na folha. O problema da comissão de outras porções da imagem à classe de folhas atacadas, precisa ser solucionado, pois é um erro grave que poderia levar o programa a classificar plantas saudáveis como atacadas. Uma possível solução seria associar ao programa um algoritmo capaz de identificar os pixels que representam as bordas das folhas de milho e eliminá-los da classificação refinada, o que reduziria o problema, uma vez que esta porção é a mais erroneamente classificada como atacada.

As porções de solo classificadas como folhas atacadas precisam ser mais estudadas em outras imagens, uma vez que a imagem analisada apresenta, na parte sombreada, e próximo à folha do milho, folhas de plantas daninhas e palha, difíceis de serem identificadas até mesmo visualmente. A dificuldade da identificação dessa classe é maior, uma vez que a classe aqui denominada solo na realidade agrega classes distintas, como palha e solo propriamente dito. Este impasse pode ser minimizado utilizando-se um número maior de amostras para o treinamento das redes neurais, oriundas de várias imagens, em condições diferentes e/ou identificando-se a borda da folha, permitindo ao programa, dessa maneira, concluir se está ou não analisando a superfície da folha.

CONCLUSÕES

1. As redes neurais com maior número de neurônios nas camadas ocultas (15-10 e 20-10) apresentaram o melhor resultado tanto com as amostras de treinamento como com as amostras de teste.

2. O índice do excesso de verde normalizado, associado a um limiar, foi eficiente para separar os pixels representando folhas saudáveis dos demais constituintes da imagem. As áreas da folha atacadas pela lagarta foram perfeitamente segmentadas por esse método.

3. O método da contagem de pixels representando folhas saudáveis foi eficiente para classificação grosseira dos blocos da imagem, reduzindo desta forma o número de pixels a serem processados na fase de classificação refinada.

4. As redes neurais selecionadas (15-10 e 20-10) apresentaram desempenho semelhante, mostrando-se eficientes para classificar as folhas saudáveis; a eficiência foi menor na classe solo devido à sua heterogeneidade em cor e textura. As imagens classificadas pelas duas redes mostraram-se praticamente idênticas, com exatidão global da amostragem de 80,72%.

LITERATURA CITADA

- Allen, J.C.; Kopp, D.D.; Brewster, C.C.; Fleischer, S.J. 2011: An agricultural odyssey. *American Entomologist*, Lanham v.45 n.2, p.96-104. 1999.
- Bacci, L.; De Vincenzi, M.; Rapi, B.; Arca, B.; Benincasa, F. Two methods for the analysis of colorimetric components applied to plant stress monitoring. *Computers and Electronics Agriculture*, Oxford, v.19, p.167-186, 1998.
- Barnes, E.M.; Moran, M.S.; Pinter Jr., P.J.; Clarke, T.R. Multispectral remote sensing and site-specific agriculture: Examples of current technology and future possibilities. *Precision Agriculture – Proceedings of the 3rd International Conference, ASA/CSSA/SSSA*, Madison, p. 845-854, 1996.
- Campbell, J.B. *Introduction to remote sensing*. New York: The Guilford Press. 1987. 551p.
- Carvalho, R.P.L. Pragas do milho. In: Paterniani, E.; Viégas, G.P. (ed.) *Melhoramento e produção de milho*. Campinas: Fundação Cargill. v.2, 2 ed. p.637-712. 1987.
- Cruz, I; Turpin, F.T. Efeito de *Spodoptera frugiperda* em diferentes estádios de crescimento da cultura do milho. *Pesquisa Agropecuária Brasileira*, Brasília, v.17 n.3, p.355-359, 1982.
- Daberkow, S.; Christensen, L. The potential contributions of precision farming to IPM. *Precision Agriculture - Proceedings of the 3rd International Conference, ASA/CSSA/SSSA*, Madison, p.567-568, 1996.
- Fancelli, A.L.; Dourado Neto, D. *Produção de milho*. Guaíba: Livraria e Editora Agropecuária, 2000. 360p.
- Guyer, D.E.; Miles, G.E.; Schreiber, M.M.; Mitchell, O.R.; Vanderbilt, V.C. Machine vision and image processing for plant identification. *Transactions of the ASAE*. St. Joseph, v.29, n.6, p.1500-1507, 1986.
- 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.
- Jia, J.; Krutz, G.W. Location of the maize plant with machine vision. *Journal of Agricultural Engineering Research*, London, v.52, p.169-181, 1992.
- Lippmann, R.P. An introduction to computing with neural nets. *IEEE Acoustics Speech and Signal Processing Magazine*, Washington, v.2, n.4, p.4-22, 1987.
- Mitchell, T.M. *Machine learning*. Boston: McGraw Hill Companies Inc. 1997. 414p.
- 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
- Park, B.; Chen, Y.R. Multispectral image co-occurrence matrix analysis for poultry carcasses inspection. *Transactions of the ASAE*. St. Joseph, v. 39, n.4, p.1485-1491, 1996.
- Pérez, A.J.; López, F.; Benlloch, J.V.; Christensen, S. Colour and shape analysis techniques for weed detection in cereal fields. *Computers and Electronics in Agriculture*, Oxford, v.25, p.197-212, 2000.

- 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.
- Shearer, S.A.; Holmes, R.G. Plant identification using color co-occurrence matrices. Transactions of the ASAE. St. Joseph, v 33, n.6, p.2037-2044, 1990.
- Shearer, S.A.; Payne, F.A. Color and defect sorting of bell peppers using machine vision. Transactions of the ASA. St. Joseph, v.33 n.6, p.2045-2050 1990.
- Waquil, J.M.; Viana, P.A.; Lordello, A.I.; Cruz, I.; Oliveira, A.C. Controle da lagarta do cartucho em milho com inseticidas químicos e biológicos. Pesquisa Agropecuária Brasileira, Brasília, v.17 n.2, p.163-166, 1982.