

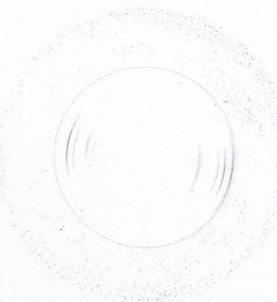


XI Encontro de Modelagem Computacional

17 a 19 de novembro de 2008



Organização



Organizadores

José Adilson de Castro
Alexandre S. Francisco
Francisco D. Moura Neto

Realização

Escola de Engenharia Industrial Metalúrgica de Volta Redonda/UFF

Apoio

CNPq
PUVR

Editora



ISBN 978-85-228-0487-0

**DESENVOLVIMENTO DE UM MODELO DE DESCRITORES DE IMAGENS
PARA RECONHECIMENTO DE PADRÕES DE PLANTAS INVASORAS
(FOLHAS LARGAS E FOLHAS ESTREITAS)**

Ana Paula de Oliveira Santos- ana_santos@dc.ufscar.br

Universidade Federal de São Carlos, Departamento de Computação - CCET
13565-905 - São Carlos, SP, Brasil

Paulo E. Cruvinel- cruvinel@cnpdia.embrapa.br

Embrapa Instrumentação Agropecuária
CP 741 13560-970 São Carlos, SP, Brasil

Resumo. No Brasil ainda é embrionário o desenvolvimento de ferramentas de reconhecimento de pragas e plantas invasoras, capazes de auxiliar a tomada de decisão e indicar o risco na lavoura. Este trabalho apresenta um modelo para o desenvolvimento de descritores utilizando técnicas de processamento digital de imagens para o estabelecimento de uma técnica específica de reconhecimento de padrões de folhas largas e estreitas de plantas invasoras. O resultado proporcionará a configuração de uma base de informação para o auxílio à tomada de decisão em processos de pulverização agrícola.

Palavras-chave: Descritores, Reconhecimento de Padrões, Plantas Invasoras

1. INTRODUÇÃO

A linha de estudos relacionados ao uso de visão computacional para o auxílio à tomada de decisão em ambiente agrícola para controle de plantas invasoras, também conhecidas como plantas daninhas, despertou a atenção de diversos pesquisadores por todo o mundo preocupados com o grande número de trabalhos publicados em controle químico e poucos estudos relacionados à biologia de suas plantas.

O desequilíbrio ocasionado por variáveis ambientais torna propícia a explosão populacional de certas plantas no ambiente agrícola, podendo ocasionar infestação de plantas invasoras. A partir de informações ambientais, pode-se inferir qual o nível de risco de uma cultura ser atacada por alguma praga. A partir da praga já instalada, pode-se inferir a capacidade de dispersão da mesma pela cultura. A previsão das pragas, com base em protocolos que viabilizem o seu reconhecimento com taxa mínima de erro, auxiliará em modelos que viabilizem o combate das mesmas, avisando o agricultor quanto à ocorrência para que medidas necessárias de prevenção como a dispersão de defensivos agrícolas em regiões precisas seja executada.

O aumento substancial no uso de herbicidas tem sido uma tendência crescente para compensar as deficiências do controle mecânico tradicional (Felton et al., 1991).

Pesquisadores têm buscado meios para reduzir a quantidade de defensivos e o impacto sobre o meio ambiente. A variabilidade espacial das plantas invasoras tem sido objeto de estudo com o objetivo de diminuir o volume de defensivos aplicados com base no uso de mapeamento das áreas infestadas (Willis & Stoller, 1990; Chancellor & Goronea, 1994; Tian et al., 1999).

A agricultura de precisão, também conhecida como *Precision Agriculture*, *Precision Farming* ou ainda *Site-Specific Crop Management*, reúne o uso de tecnologias para o manejo de solo,

insumos e culturas, de modo adequado às variações espaciais e temporais em fatores que afetam a produtividade das mesmas, com o objetivo de aumentar a eficiência produtiva (Tschiedel & Ferreira, 2002).

Dentre as ferramentas utilizadas na agricultura de precisão destaca-se o sensoriamento remoto, muito utilizado para o mapeamento de áreas de cultura e estimação do rendimento das mesmas. Entretanto, nos últimos anos a pesquisa tem sido direcionada para o monitoramento das condições da cultura como, por exemplo, a identificação das deficiências nutricionais da planta, ocorrência de pragas e doenças, classificação e quantificação de plantas invasoras, dentre outros (Goel et al., 2000). A detecção de plantas invasoras através do sensoriamento remoto orbital ainda possui limitações quanto à resolução espacial e temporal. Acredita-se que existe potencial para utilização de sistemas de visão artificial como sensores para coleta de dados em agricultura de precisão (Pinto et al., 1999). Tais sistemas são constituídos, 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.

2. METODOLOGIA

O modelo desenvolvido é parte de um projeto temático em agricultura de precisão, desenvolvido pela Embrapa em parceria com outras instituições do Brasil e exterior, e tem por objetivo aplicar técnicas de visão computacional e processamento de imagens para o reconhecimento de plantas invasoras presentes na cultura do milho (*Zea mays*).

Foram consideradas imagens georeferenciadas adquiridas por câmera digital e pré-processadas para obter uma melhor qualidade da imagem. Uma técnica de textura, baseada no uso de matriz de co-ocorrência, foi vista para selecionar apenas as plantas invasoras presentes na imagem. A partir deste ponto foram vistos alguns descritores para definição e diferenciação das folhas largas e estreitas. Para a classificação foi utilizada uma técnica baseada em Bayes, que proporciona percentuais de identificação dos padrões de folhas largas e estreitas, utilizados como elemento para inferir volumes diferenciados de herbicidas a serem lançados nos respectivos quadros das imagens adquiridas.

2.1 Aquisição da imagem

É feita através de uma câmera digital, em posição perpendicular ao solo, sob condições naturais de iluminação e durante o crescimento da cultura, em áreas amostradas do campo de produção e em intervalos de tempo pré-determinados, em função da espécie cultivada considerada.

2.2 Pré-processamento

Nesta etapa a imagem é preparada para o processamento efetivo, através da equalização do histograma, cujo objetivo é melhorar o contraste da imagem, e da técnica de filtragem da mediana, responsável pela suavização da imagem, eliminando os ruídos da mesma.

2.3 Análise de textura

É utilizado um método estatístico baseado na extração das características texturais da imagem através da matriz de co-ocorrência dos níveis de cinza (GLCM - *Grey Level Cooccurrence Matrix*). Uma GLCM é uma matriz de tamanho $N_g \times N_g$, onde N_g é o número de níveis de cinzas, definida para um deslocamento de uma distância d junto com uma determinada direção θ . A entrada $p(i, j)$ desta matriz é o número de ocorrências de um par de níveis cinza, i e j , para

um deslocamento e ângulo especificados. Uma vez que a GLCM é definida, vários descritores texturais podem ser obtidos (Haralick et al., 1973), tais como entropia, energia, contraste, homogeneidade e correlação. Neste trabalho foi considerado o descritor de correlação, definido a seguir:

Correlação: é uma medida do grau de associação linear (negativa ou positiva) entre duas variáveis quantitativas. A correlação mede a dependência linear de um nível de cinza em relação aos vizinhos.

$$Correlacao = \frac{\sum_i \sum_j (ij) \cdot p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (1)$$

onde μ_x e μ_y representam as médias nas direções x e y , respectivamente e σ_x e σ_y representam os desvios padrões.

2.4 Descritores para as folhas

São utilizados alguns descritores de forma e baseados em momentos, e o que irá diferir os descritores de folhas largas e os de folhas estreitas são os valores dos mesmos, mas em ambos os casos, o conjunto de descritores será o mesmo. Os descritores utilizados são:

Redondez: é uma razão baseada nos descritores de área e perímetro, onde o perímetro mede a quantidade de pixels em torno do contorno do objeto e a área refere-se a área do interior do objeto, computada como o número total de pixels dentro do objeto, incluindo seu contorno. O resultado é a medida de redondez do objeto, dada por um valor entre 0 e 1. A maior razão é 1, quando o objeto é um círculo perfeito, com a diminuição da razão, o objeto parte de uma forma circular.

$$Redondez = \frac{4\pi \times Area}{Perimetro} \quad (2)$$

onde $Perimetro \neq 0$.

Circularidade: também é obtida por uma razão dos descritores de perímetro e área, sendo representada pela fórmula a seguir:

$$Circularidade = \frac{Perimetro^2}{Area} \quad (3)$$

onde $Area \neq 0$.

Elongação: é uma razão computada pela distância da largura do menor eixo dividida pela distância do comprimento do maior eixo, sendo que o maior eixo é a direção ao longo da qual a forma é mais alongada, e o menor eixo é a linha mais longa que pode ser traçada dentro do objeto, mantendo perpendicularidade com o eixo principal. O resultado é a medida da elongação do objeto, dada por um valor entre 0 e 1, onde a razão igual a 1 significa que o objeto é aproximadamente de forma quadrada ou redonda, e conforme a razão vai diminuindo, mais alongado é o objeto.

$$Elongacao = \frac{largura}{comprimento} \quad (4)$$

onde $comprimento \neq 0$.

Momentos Invariantes: são descritores úteis em problemas de reconhecimento de padrões, e para análise de formas. Usando N momentos, por exemplo, a imagem pode ser representada como um ponto em um espaço de vetor N -dimensional. Um conjunto de momentos invariantes a translação, rotação e mudança de escala, foi apresentado por Hu (1962) e é apresentado abaixo:

$$\begin{aligned}
 \phi_1 &= \eta_{20} + \eta_{02} \\
 \phi_2 &= (\eta_{20} + \eta_{02})^2 + 4\eta_{11}^2 \\
 \phi_3 &= (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \\
 \phi_4 &= (\eta_{30} + 3\eta_{12})^2 + (\eta_{21} + \eta_{03})^2 \\
 \phi_5 &= (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12}) [(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + \\
 &\quad (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03}) [3(\eta_{30} + 3\eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\
 \phi_6 &= (\eta_{20} - \eta_{02}) [(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \\
 \phi_7 &= (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12}) [(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + \\
 &\quad (3\eta_{12} - \eta_{30})(\eta_{21} + \eta_{03}) [3(\eta_{30} + 3\eta_{12})^2 - (\eta_{21} + \eta_{03})^2]
 \end{aligned} \tag{5}$$

2.5 Classificação

Para a classificação é utilizada a teoria de decisão de Bayes, que é uma das teorias fundamentais para o problema de classificação de padrões, pois o assunto é posto em termos de suas probabilidades (Duda et al., 2001).

3. DISCUSSÃO DO MODELO

O presente modelo será utilizado como ferramenta de apoio para a tomada de decisão em processos de pulverização agrícola, visando a diminuição da quantidade de defensivos aplicada, e conseqüentemente o impacto ambiental, no controle de plantas invasoras presentes na cultura do milho (*Zea mays*).

A partir da metodologia apresentada na seção anterior foi criado o diagrama ilustrado na figura 1, no qual constam a etapa de aquisição das imagens, sendo elas georeferenciadas e adquiridas por câmera digital; pré-processamento, para eliminação de ruídos e equalização visando um ajuste de ambiente e contraste; análise de textura para selecionar apenas as plantas invasoras presentes na imagem; descritores, para o reconhecimento do tipo de folha (larga ou estreita); e classificação para proporcionar os percentuais de identificação para inferir volumes diferenciados de herbicidas a serem lançados, ou seja, técnicas específicas para combate às plantas invasoras de folhas largas e às plantas de folhas estreitas. Também foi incluída uma etapa que armazena em um repositório as imagens adquiridas e processadas nas várias partes do processo de análise.

Dados a metodologia e o diagrama, foi estruturado um pseudo-código geral do modelo, que é apresentado na figura 2, no qual constam as seguintes etapas:

Aquisição da imagem: dois tipos de imagens foram considerados. Primeiramente, para a análise dos descritores, foram consideradas imagens das folhas individuais (um tipo de folha por imagem) para a seleção dos descritores que melhor distinguem as espécies de plantas (folhas largas e folhas estreitas) e depois imagens da plantação, com cultura, e plantas invasoras, sob condições naturais de iluminação.

```

variáveis
    ng: inteiro {Número de níveis de cinza da imagem}
fim-variáveis

Begin
    variáveis
        tamMasc: inteiro
        mc[ng][ng]: inteiro
        deslocamento, ângulo: inteiro
        vetorDesc[4]: real
    fim-variáveis
    {Aquisição da imagem}
    Begin
        leia(imagem)
    end;
    {Pré-Processamento da imagem}
    Begin
        equalizaHistograma(imagem)
        {Filtragem}
        leia(tamMasc)
        filtroMediana(imagem, tamMasc)
    end;
    {Bloco de Análise de Textura}
    Begin
        mc <- matrizCoOcorrencia(imagem, deslocamento, ângulo)
        classifica(correlação(mc))
    end;
    {Bloco de Reconhecimento de Padrões}
    Begin
        {Descritores}
        Begin
            vetorDesc[0] = redonez(area(imagemForma), perimetro(imagemForma))
            vetorDesc[1] = retangular(area(imagemForma), areaCE(imagemForma))
            vetorDesc[2] = alongação(larg(imagemForma), compr(imagemForma))
            vetorDesc[3] = momento(imagemForma)
        end;
        {Classificação}
        Begin
            classificaçãoBayes(vetorDesc)
        end;
    end;
end.

```

Figure 2: Pseudo-código do modelo apresentado.

Banco de imagens: foi adicionado para armazenar as imagens adquiridas e processadas durante todas as etapas do processo, visando manter um histórico das mesmas para análises futuras.

Como já mencionado anteriormente, a cultura escolhida para o estudo de caso do modelo é a cultura do milho (*Zea mays*), sendo que pretende-se reconhecer dois tipos de plantas de folhas largas, e dois tipos de folhas estreitas. Os tipos escolhidos são os mais comuns na cultura em questão, sendo a leiteira e o picão-preto, *Euphorbia heterophylla* L. e *Bidens pilosa*, respectivamente, plantas de folhas largas, e o capim-colchão e o capim-carrapicho, *Digitaria sanguinalis* Scop. e *Cenchrus echinatus* L., respectivamente, plantas de folhas estreitas.

Agradecimentos

Este trabalho é desenvolvido com o apoio da Embrapa Instrumentação Agropecuária (São Carlos/SP), Embrapa Milho e Sorgo (Sete Lagoas/MG) e Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

REFERÊNCIAS

- Chancellor, W. J. & Goronea, M. A., 1994. Effects of spatial variability of nitrogen, moisture and weeds on the advantages of site-specific applications for wheat. *Transactions of the ASAE*, vol. 37, n. 3, pp. 717-724.
- Duda, R. O., Hart, P. E., & Stork, D. G., 2001. *Pattern classification*. Wiley New York.
- Felton, W. L., Doss, A. F., Nash, P. G., & McCloy, K. R., 1991. A microprocessor controlled technology to selectively spot spray weeds. In *Proceedings of the Automated Agricultural for the 21st Century Symposium*, pp. 427-432, December 1617, Chicago.
- Goel, P. K., Prasher, S. O., Patel, R. M., Smith, D. L., & DiTommaso, A., 2000. Airborne optical remote sensing for detection of weed infestation in site-specific management of field crops. Technical Report Paper No. 0003056, International Meeting of the American Society of Agricultural Engineers (ASAE).
- Haralick, R., Shanmugam, K., & Dinstein, I., 1973. Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 3, n. 6, pp. 610-621.
- Hu, M. K., 1962. Visual pattern recognition by moment invariants. *Information Theory, IEEE Transactions on*, vol. 8, n. 2, pp. 179-187.
- Pinto, F. A. C., Jr, D. G. S., Queiroz, D. M., & Gomide, R. L., 1999. Visão artificial na agricultura de precisão. *Avanços na Agricultura de Precisão no Brasil no período*, vol. 2001, pp. 309-316.
- Tian, L., Reid, J. F., & Hummel, J. W., 1999. Development of a precision sprayer for site-specific weed management. *Transactions-American Society of Agricultural Engineers*, vol. 42, pp. 893-902.
- Tschiedel, M. & Ferreira, M. F., 2002. Introdução à agricultura de precisão: conceitos e vantagens. *Ciência Rural*, vol. 32, n. 1.
- Willis, B. D. & Stoller, E. W., 1990. Weed suppression for vegetation management in corn and soybeans. *Proc. N. Centr. Weed. Sci. Soc.*, vol. 45, n. 9.

A DESCRIPTORS DEVELOPMENT MODEL FOR WEED RECOGNITION
(WIDE AND NARROW LEAVES)

Abstract. *In Brazil, the development of tools for weeds and plague recognition capable of helping decision making and risk detection in crops fields is still embryonic. This paper introduces a descriptors development model using digital image processing techniques for the establishment of a specific technique of weed recognition, wide and narrow leaves. The result will provide the configuration of an information base for aiding decision making in agric sprays.*

Keywords: *Descriptors, Pattern Recognition, Weed*