



AFSOT – SOFTWARE PARA ANÁLISE FOLIAR

LÚCIO A. C. JORGE¹, DANIEL J. C. B. SILVA²

¹Pesquisador, Embrapa Instrumentação Agropecuária, São Carlos – SP, Fone: (0XX16) 2107.2800, lucio@cnpdia.embrapa.br

²Graduando em Engenharia de Computação, Universidade Federal de São Carlos, São Carlos – SP

Apresentado no
Congresso Brasileiro de Agricultura de Precisão – ConBAP 2010
Ribeirão Preto – SP, 27 a 29 de setembro de 2010

RESUMO: As atividades de inspeção de pragas e doenças durante o desenvolvimento de uma cultura é uma prática que exige treinamento de inspetores e geralmente são feitas de forma manual e visual. O desenvolvimento de um sistema especialista, que poderia processar imagens de folhas de plantas capturadas no campo minimizaria os problemas de treinamentos, análises subjetivas e permitiria um padrão de identificação de pragas, doenças e deficiências de forma mais eficiente e precisa. Assim, o presente trabalho mostra um software desenvolvido capaz de automatizar a análise de imagens digitais de folhas em grandes lotes, permitindo a inspeção e quantificação rápida e precisa dos diferentes aspectos presentes na área analisada, auxiliando, assim, a tomada de decisão. O software AFSOT foi disponibilizado gratuitamente no site www.cnpdia.embrapa.br/labimagem e está sendo utilizado em diferentes estudos e diferentes culturas, apresentando taxas de acerto superiores a 90% quando comparado com metodologia convencional de análise foliar. Quando adquirida a imagem com as coordenadas da planta, é possível gerar rapidamente mapas de doenças, pragas e deficiências, quando detectadas por sintomas na imagem.

PALAVRAS-CHAVE: análise foliar, redes neurais, inspeção de pragas

AFSOT - SOFTWARE FOR LEAF ANALYSIS

ABSTRACT: An Inspection activity of leaf diseases of crop growing requires training of inspectors and are usually done manually and visually. The development of an expert system that could process images of leaves at field conditions could minimize the problems of training, subjective analysis and allow a pattern identification of diseases and efficiency more effectively and accurately. Thus, this work shows a software developed for automating the analysis of digital images of leaves in large batches, allowing fast and precise quantification of the various issues from the crop area, helping thereby to decision making. AFSOT is free software that is available on the site www.cnpdia.embrapa.br/labimagem and is being used in different studies and different cultures, in general, with 90% of accuracy rates when compared with conventional methods of leaf analysis. When the image is acquired with the coordinates of the plant, you can quickly generate maps of diseases, pests and weaknesses, when detected by symptoms in the image.

KEYWORDS: leaf analysis, neural networks, inspection

INTRODUÇÃO: Segundo Plant (2001), agricultura de precisão é compreendida pelo uso da tecnologia de informação em todo ciclo da produção agrícola, um processo em prol da agricultura sustentável. Assim todas as ações auxiliadas pela tecnologia atual tem o objetivo de aumentar a eficiência na utilização de insumos e recursos naturais (ZHANG et al., 2002), tornando a tomada de decisão mais precisa, minimizando erros. A folha de um cultivo tem papel importante no desenvolvimento da planta uma vez que é responsável pela fotossíntese, respiração e transpiração

(TAIZ & ZEIGER, 2004). Assim a identificação de diferentes características presentes na folha bem como a área foliar representada por cada uma delas é de suma importância para estudos realizados nas áreas de fitopatologia e fisiologia, tornando possível, a partir da avaliação das folhas, administrar ações na cultura como a poda ou aplicação de defensivos e insumos. Logo, a análise do desenvolvimento das folhas de uma cultura, destacando seu comportamento frente a algumas variáveis como a ação de intempéries, ataque de pragas ou deficiências nutricionais é de suma importância a fim de auxiliar na execução de medidas preventivas ou corretivas. O uso de técnicas de processamento de imagens de folhas da cultura destaca-se como uma ferramenta de grande potencial para aquisição de parâmetros que auxiliam na tomada de decisão. Assim a análise de imagens digitais desponta como um artifício capaz de identificar aspectos importantes da área foliar como as propriedades e o estado de sanidade e desenvolvimento da cultura. Portanto, é evidente a demanda de um sistema especialista capaz de automatizar a análise de imagens digitais de folhas, para que permita a inspeção e quantificação rápida e precisa dos diferentes aspectos presentes na área analisada, auxiliando, assim, a tomada de decisão.

MATERIAL E MÉTODOS: Para o desenvolvimento deste trabalho foram utilizadas algumas *Application Programming Interface* (API) disponíveis na linguagem de programação Java como: a *Java Advanced Imaging* (JAI), a *Java Excel* (JXL) e a *Waikato Environment Knowledge Analysis* (WEKA).

Uma imagem digital é constituída por uma matriz de dados em que cada posição armazena informações do pixel, a menor unidade de representação de uma imagem digital, cujo tamanho depende da resolução da imagem em questão. Cada pixel, por sua vez, é constituído por três valores inteiros que representam a sua cor no espaço de cores RGB (*Red*, *Green* e *Blue*). Os valores inteiros do pixel variam entre 0 e 255 em que a cor preta é representada por todos os valores 0 (zero) enquanto que a cor branca é representada por todos os valores 255; todas as outras cores são representadas por combinações de valores intermediários. Assim, para manipular ou coletar informações da imagem foi utilizada a API JAI.

A inteligência artificial é um ramo da computação que procura simular o cérebro humano em uma máquina. Especificamente neste trabalho foi usado um tipo de rede neural denominada supervisionada. Para que este tipo de rede reconheça e divida um determinado conjunto de dados em classes, exemplos de dados e sua respectiva classe devem ser informados previamente para que a rede seja construída ou treinada a partir destes exemplos. A API WEKA é um pacote disponível que contém vários métodos de mineração de dados e de inteligência artificial. Dentre os vários métodos de inteligência artificial implementados no pacote WEKA está a rede neural *MultiLayer Perceptron* (MLP) que foi utilizada no trabalho para o reconhecimento dos padrões.




Figura 1 – Esquema de uma rede neural MLP

Sendo assim, a primeira etapa da construção de um classificador, a partir de uma rede neural supervisionada, é a determinação das classes de padrões bem como os padrões destas. Nesta etapa um especialista faz-se necessário para, através de janelas de seleção na imagem, determinar características das classes guiando-se pelas diferentes tonalidades de cores.



Figura 2 – Determinação de um padrão da classe “necrose” através de janelas de seleção

A segunda etapa é a criação de um classificador a partir da rede neural MLP com o algoritmo de backpropagation (BP) ou retro-propagação de erro. O algoritmo BP é caracterizado por dois passos principais: o processamento direto e o processamento reverso. O primeiro consiste em submeter uma entrada à rede neural e o resultado é propagado por todas as camadas da rede até a saída. Já o segundo, um sinal de erro é calculado na saída e este é propagado no sentido inverso por todas as camadas da rede neural. Segundo Jorge & Crestana (2007) a regra de aprendizado denominada “Regra Delta” ou Minimização do Erro Médio Quadrático (LMS) tem a função de determinar um conjunto de pesos e polarizações das conexões entre os neurônios de modo que a função erro seja minimizada. A saída de cada neurônio na rede neural é produzida através de uma função de ativação sigmoidal. O treinamento do algoritmo BP é descrito pelo fluxograma de operação a seguir.




Figura 3 – Fluxograma de funcionamento do BP

A primeira etapa trata da inicialização de todos os parâmetros de treinamento e a seguir são apresentados à rede os exemplos de padrões de classes colhidas pelo especialista. O próximo passo consiste na determinação do erro fazendo a diferença entre a saída desejada e a saída gerada e fazer com que este se propague reversamente pela rede. Por fim, os pesos das conexões entre os neurônios da rede neural são ajustados segundo o LMS e se o erro total calculado for desprezível o treinamento encerra-se, senão o processo reinicia até que o erro seja desprezível.

Assim o software foi desenvolvido baseado na rede neural MLP em que os padrões de entrada são os valores RGB da imagem a ser classificada. Após a fase de treinamento, tem-se a identificação das folhas e classificação ou análise de uma ou um lote de imagens. Adotou-se o seguinte fluxo de operações até a classificação de uma imagem pela rede neural sendo que os resultados obtidos são expostos em tabelas.




Figura 4 – Fluxograma de operações do AFSOft

RESULTADOS E DISCUSSÃO: Os métodos utilizados na classificação da imagem com rede neural MLP foram implementados na linguagem JAVA resultando em um aplicativo simples tanto para a aquisição de padrões e treinamento quanto para a classificação. Uma aquisição de padrões mais precisa e minuciosa resulta em um treinamento e resultado melhores. Sendo assim, um recurso de zoom foi implementado para auxiliar este processo, assegurando que a janela selecionada não contenha informações indesejadas. Para o caso de uma folha de uma cultura de soja, o zoom auxilia na precisão em determinar padrões de região sadia e região afetada pela ferrugem. A seguir são exemplificadas coletas de um mesmo padrão “Ferrugem” em que na figura 5 a seleção é feita sem o recurso de zoom e na figura 6 a seleção é feita com recurso de zoom.



Figura 5 – Seleção de padrão de “Ferrugem” sem o zoom



Figura 6 – Seleção de padrão de “Ferrugem” com o zoom

O tipo de seleção representado na figura 6 melhora o resultado da classificação uma vez que é feito com o recurso de zoom, aumentando a precisão e evitando padrões de cor indesejáveis. Depois de coletados os padrões de todas as classes desejadas e feito o treinamento obteve-se os seguintes resultados de classificação das imagens.




Figura 7 – Sequência de operação até o resultado final

Além da representação dos resultados em imagens classificadas foi possível quantificar tanto em porcentagem quanto em área os padrões encontrados na imagem como mostrados a figura 8.



Figura 8 – Resultados da classificação

CONCLUSÕES: O uso de redes neurais para a classificação de imagens de folhas de uma cultura mostrou-se muito rápido e eficiente. Assim, com o AFSOft v1.0 é possível classificar e quantificar precisamente classes de padrões presentes nas imagens, podendo, portanto, auxiliar o usuário na tomada de decisão.

REFERÊNCIAS:

- TAIZ, L.; ZEIGER, E. Fisiologia vegetal. 3. ed. Porto Alegre: Artmed, 2004. 719 p.
- PLANT, R. E. Site-specific management: the application of information technology to crop production. Computers and Electronics in Agriculture, 30:9-29, 2001.
- ZHANG, N., WANG, M., WANG, N. Precision agriculture-a worldwide overview. Comp. Electron. Agric. 36:113-132, 2002.
- JORGE, L. A. de C.; CRESTANA, S. Processamento de imagens em ciência do solo: raízes, morfologia e cobertura do solo. In: MARTIN NETO, L.; VAZ, C. M. P.; CRESTANA, S. (Ed.). Instrumentação avançada em ciência do solo. São Carlos, SP: Embrapa Instrumentação Agropecuária, 2007. p. 341-438.