

Universidade Federal de Ouro Preto - UFOP
Instituto de Ciências Exatas e Biológicas - ICEB
Departamento de Computação - DECOM

CARACTERIZAÇÃO AUTOMÁTICA DOS AGENTES
CAUSADORES DE LESÕES EM FOLÍOLOS DE
CULTIVARES DO BRASIL

Aluno: Suellen Silva de Almeida
Matricula: 08.1.4020

Orientador: David Menotti

Ouro Preto
17 de junho de 2011

Universidade Federal de Ouro Preto - UFOP
Instituto de Ciências Exatas e Biológicas - ICEB
Departamento de Computação - DECOM

CARACTERIZAÇÃO AUTOMÁTICA DOS AGENTES
CAUSADORES DE LESÕES EM FOLÍOLOS DE
CULTIVARES DO BRASIL

Relatório de atividades desenvolvidas apresentado ao curso de Bacharelado em Ciência da Computação, Universidade Federal de Ouro Preto, como requisito parcial para a conclusão da disciplina Monografia I (BCC390).

Aluno: Suellen Silva de Almeida
Matricula: 08.1.4020

Orientador: David Menotti

Ouro Preto
17 de junho de 2011

Resumo

Na agricultura, são muitas as dificuldades encontradas durante o manejo de pragas na lavoura. São muitos os tipos de ataques de pragas, sendo um deles feito diretamente nas folhas das plantas. A preservação dos folíolos é de suma importância para a vida da planta e para a manutenção da produção de frutos (*e.g.* grãos). Portanto, a caracterização dos agentes causadores (*e.g.*, coleópteros, lagartas, etc.) do desfoliamento ou danos, ou ainda lesões, em folíolos de cultivares, em conjunto com a detecção automática da área foliar danificada, são essenciais para a determinação de ações de controle, visto que determinados agentes podem dispensar medidas de controle, dado seus potenciais.

Este projeto propõe desenvolver e implementar algoritmos e métodos de caracterização/classificação automática dos agentes causadores de danos em lavouras. Esses métodos trabalharão com imagens digitais capturadas por meio de câmeras (pelos próprios agricultores) e/ou *scanners*. Trabalhamos com a hipótese de que por meio da análise de texturas e coloração dos folíolos é possível identificar, caracterizar e diferenciar os agentes causadores de danos aos folíolos de cultivares brasileiros. Esses novos métodos reduzirão o tempo demandado para a avaliação e aumentarão a confiabilidade da análise foliar.

Palavras-chave: Processamento de Imagens. Agentes Causadores de Lesões em Folíolos.

Sumário

1	Introdução	1
2	Justificativa	2
3	Objetivos	3
3.1	Objetivo geral	3
3.2	Objetivos específicos	3
4	Metodologia	4
5	Desenvolvimento	5
5.1	Preprocessamento	5
5.2	Extração de características	6
5.2.1	Descritores a partir de redes complexas	6
5.2.2	Descritores de Fourier	9
5.2.3	Descritores Wavelet	9
5.2.4	Descritores de Zernike	10
5.3	Classificação	10
5.4	Experimentos	11
5.5	Experimentos com os descritores de Fourier, Wavelet e Zernike	11
5.6	Experimentos com os descritores baseados em redes complexas	12
6	Trabalhos Futuros	12
7	Cronograma de atividades	13

Lista de Figuras

1	Etapas de desenvolvimento do método de caracterização automática . . .	4
2	Recortes em folíolos de soja: (a) Dano atribuído a coleópteros; (b) Dano atribuído a lagartas.	5
3	Exemplo ilustrativo: (a) Imagem de entrada com os danos rotulados; (b) Processo de filtragem [11]; (c) Extração do contorno do dano. . . .	6
4	Resultado obtido para uma amostra: (a) Classificação com os descritores de Fourier e Zernike; (b) Classificação com os descritores de Wavelet. .	11

Lista de Tabelas

1	Precisão para classificação dos agentes danificadores e sensibilidade para as classes coleóptero (SenB) e lagarta (SenC) utilizando diferentes descritores. Os valores em parênteses representam o desvio padrão da precisão para o esquema de validação cruzada.	12
2	Precisão para classificação dos agentes danificadores e sensibilidade para as classes coleóptero (SenB) e lagarta (SenC) utilizando diferentes valores T_l . Os valores em parênteses representam o desvio padrão da precisão para o esquema de validação cruzada <i>10-fold</i>	13
3	Cronograma de Atividades.	13

1 Introdução

Na agricultura, são muitas as dificuldades enfrentadas durante o manejo de pragas na lavoura. Existem vários tipos de ataques de pragas, sendo que um deles acontece diretamente nas folhas das plantas. As folhas são parte essencial da planta para a produção dos frutos, pois é através delas que a energia solar é captada e transformada em grande parte do alimento da planta. Um comprometimento dessa área de recepção de energia pode acarretar em um grande dano a produção dos frutos (*e.g.* grãos). Uma maneira de diagnosticar o nível de comprometimento do folíolo é determinar a área danificada e também o agente causador do dano (*e.g.* coleopteros, lagartas, etc.).

A determinação do grau de infestação e da praga é necessária para que o agricultor possa tomar medidas cabíveis em relação ao combate a essas pragas. Essas avaliações geralmente são feitas de forma não metodológica e visual por um agrônomo, estando sujeita a erros devido a dificuldade de interpretação completa do estado do folíolo.

Além disso a determinação equivocada do agente causador dos danos na lavoura pode levar a um total desperdício de recursos econômicos quando do manejo da lavoura. Por exemplo, a aplicação de determinado agrotóxico pode ser totalmente ineficiente ao combate de uma praga, enquanto seria totalmente nociva a outra. Sem levar em conta ainda os prejuízos acarretados aos grãos e a nossa saúde.

Apesar da sua importância, poucas são as pesquisas sobre avaliações automáticas usando medidas quantitativas e não subjetivas [16]. com relação a identificação dos agentes causadores de danos. Os trabalhos que avaliam ou caracterizam os agentes causadores de danos em cultivares geralmente realizam avaliações subjetivas e não quantitativas ([3], [10], [17], [20]).

Neste projeto, propõe-se desenvolver e implementar métodos de caracterização dos agentes causadores de danos às plantas em cultivares, a partir de imagens digitais capturadas por meio de câmeras e/ou scanners ([9], [14]). Trabalhamos com a hipótese de que por meio da área e formato de cada um dos danos nos folíolos de plantas ([7], [4]). é possível caracterizar os agentes causadores dos danos. Esses métodos reduzirão o tempo demandado para a avaliação e aumentarão a confiabilidade da análise foliar.

2 Justificativa

O projeto em questão é relevante tanto nas esferas agrícola, econômica, ambiental quanto computacional.

A identificação correta do agente causador do dano que afeta os folíolos das plantas e subsequentes ações tomadas a partir dessa identificação poderão proporcionar tanto uma economia de recursos financeiros (por exemplo, na compra de agrotóxicos) quanto ambientais. A utilização do uso de agrotóxicos apenas em situações de comprovada necessidade evita os danos que esses podem causar ao ambiente e a nossa saúde.

A automatização do processo de identificação dos agentes causadores de danos em folhas de plantas não visa a eliminação da presença do especialista humano, no caso o agrônomo, mas sim a disponibilização de uma ferramenta computacional de auxílio ao diagnóstico do especialista. Além do mais, o sistema computacional, uma vez concebido, pode realizar tantos diagnósticos quantos forem necessários, sem fadiga e exaustão, mantendo sempre a mesma precisão (outra característica importante de um sistema computacional).

O produto final que pode ser gerado com a conclusão deste projeto é uma ferramenta computacional de auxílio a diagnóstico que trabalha com imagens digitais, e que pode ser implementado em sistemas embarcados - como telefones celulares. Tal ferramenta pode aumentar o interesse do agricultor/agrônomo no investimento em tecnologia, principalmente da área de processamento de imagens e reconhecimento de padrões, para auxílio em suas lavouras.

Finalmente, as áreas de processamento de imagens e reconhecimento de padrões podem ser expandidas durante o estudo da literatura. O anseio maior desse projeto é obter novas teorias matemáticas ou computacionais para a solução deste problema particular: a identificação/caracterização de agentes causadores de lesões em folíolos de cultivares brasileiros.

3 Objetivos

3.1 Objetivo geral

- O objetivo geral deste projeto é pesquisar, caracterizar e implementar um método automático para a identificação de agentes causadores de lesões em folíolos de cultivares brasileiros.

3.2 Objetivos específicos

- Fazer uma revisão da literatura sobre classificação de agentes causadores de danos em folhas de cultivares.
- Fazer uma revisão de literatura sobre processamento de imagens e reconhecimento de padrões, visando: representação digital de imagens, métodos de filtragem de imagens, técnicas de binarização, técnicas de extração de características de forma e contorno.
- Pesquisar e identificar quais técnicas de reconhecimento de padrões podem ser aplicadas na identificação dos agentes causadores de danos em folíolos de cultivares, a partir de descritores que caracterizam o contorno e a forma desses danos.
- Comparar as identificações dos agentes realizados por nosso método com a classificação de especialistas da área de fitotecnia.
- Contribuir com a divulgação de técnicas de processamento gráfico/imagens e reconhecimento de padrões à solução de problemas da agricultura, de forma que produtos agrícolas nacionais possam melhorar sua produtividade e competitividade dentro do mercado nacional e internacional.
- Produzir um artigo que possa ser publicado em um evento científico nacional e outro que possa ser submetido a revista especializada.

4 Metodologia

Inicialmente será feito um estudo das técnicas de processamento de imagens e reconhecimento de padrões relacionadas com classificação de textura e cor em objetos (no nosso caso, os folíolos). Através dessa classificação, obteremos as características que individualizam os agentes causadores de danos aos folíolos. Durante este processo classificaremos as técnicas pesquisadas.

Em seguida as técnicas pesquisadas serão implementadas, avaliadas e testadas através de descritores.

Por fim, validaremos nosso método comparando amostras coletadas com danos e suas respectivas avaliações de referência - fornecidas por especialista da área de fitotecnia. A análise dos resultados nos permitirá a preparação de artigos.

A metodologia apresentada pode ser dividida em etapas, como descrita pelo do fluxograma exibido na Figura 1.

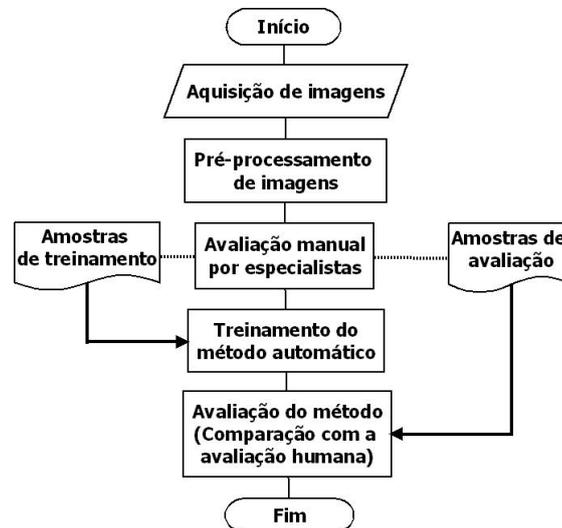


Figura 1: Etapas de desenvolvimento do método de caracterização automática

5 Desenvolvimento

Para iniciar o projeto, entramos em contato com especialistas em fitotecnia da Universidade Federal de Viçosa, o que nos levou ao conhecimento de que os principais agentes danificadores dos folíolos de soja são os coleópteros e as lagartas e que é possível distinguir essas duas classes utilizando a forma (contorno, área, etc.) de cada dano causado nos folíolos.

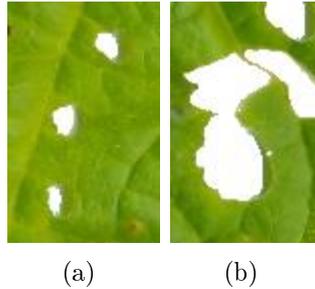


Figura 2: Recortes em folíolos de soja: (a) Dano atribuído a coleópteros; (b) Dano atribuído a lagartas.

A partir disso, foi possível pesquisar na literatura métodos para classificar os danos dos folíolos de acordo com a forma, e então construir um classificador automático para os agentes danificadores [18]. A técnica desenvolvida é composta principalmente por três passos descritos a seguir.

5.1 Pré-processamento

Nessa etapa, apresentamos o pré-processamento aplicado à imagem do folíolo para obter o contorno do dano para os próximos passos de extração de características e classificação do dano. Esse pré-processamento pode ser subdividido em dois passos; filtragem da imagem do folíolo; e extração do contorno do dano a partir da imagem do folíolo. O processo de filtragem aplicado à imagem do folíolo é o mesmo descrito em [11], e ele envolve: remoção de sombras; eliminação de resíduos; binarização; eliminação de objetos indesejáveis; e recuperação do dano interno do folíolo. Os danos nas extremidades dos folíolos são descartados. A Figura3(b) ilustra o resultado desse processo de filtragem, tendo como entrada a imagem da Figura3(a).

A partir da recuperação do dano interno do folíolo, extraímos o contorno dos danos em três subpassos, como segue: 1) Danos com área menor do que 20 pixels (0.1 inch) são descartados, porque acreditamos que eles são menos significantes para prover o diagnóstico final para o folíolo; 2) Todos os contornos dos danos são facilmente computados como uma operação de diferença de conjuntos entre a imagem com os danos obtida através do passo anterior e a imagem resultante de uma operação morfológica de erosão (veja [8]) (um exemplo de uma imagem resultante desse processo pode ser visualizada em 3(c) tendo como entrada a imagem da 3(b); 3) Uma vez que o contorno do dano é extraído, um algoritmo de rotulação [8] seguido de um processo de extração das *bounding boxes* é realizado para isolar cada contorno dos danos.

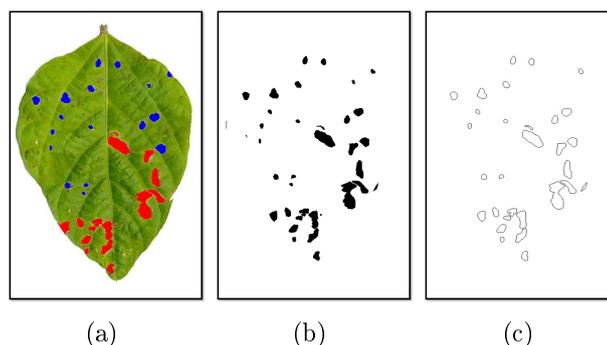


Figura 3: Exemplo ilustrativo: (a) Imagem de entrada com os danos rotulados; (b) Processo de filtragem [11]; (c) Extração do contorno do dano.

5.2 Extração de características

Para extrair as características, é necessário descrever as propriedades das mesmas, função realizada pelos descritores de características. A seguir apresentamos os descritores utilizados em [19], que são baseados em redes complexas, e os descritores de Fourier, Wavelet e Zernike, baseados em transformadas e momentos.

5.2.1 Descritores a partir de redes complexas

Uma vez que o contorno do dano é extraído, descrevemos como cada um deles é usado para modelar uma rede complexa, a então como extrair características dessa rede.

De acordo com [2], o domínio de redes complexas pode ser visto como a interseção de duas outras importantes áreas, teoria dos grafos e estatística.

Na literatura atual, podemos encontrar aplicações de redes complexas nos mais diversos ramos da ciência da computação, como mostrado em [1] e [5], que utilizam modelagem através de redes complexas em abordagens a questões como correlação entre textos e discriminação de textura. Como em [2], aplicamos redes complexas para análise do contorno das formas.

A modelagem apresentada em [2] é baseada no modelo de rede Watts-Strogatz [21]. Este modelo possui duas propriedades interessantes: 1) todos os vértices podem ser alcançados por qualquer outro com um número pequeno de arestas; 2) o grande número de ciclos mínimos (*e.g.*, tamanho 3) que eles são formados. Essas propriedades são definidas como propriedades de mundo pequeno. Adicionalmente, para extração de características, é necessário realizar uma evolução dinâmica que determina as arestas apresentadas na rede complexa por um valor limiar incrementado dinamicamente. A construção e evolução da rede será detalhada nas seguintes subseções.

Construção da Rede Complexa

A fim de modelar o contorno de uma imagem/objeto por meio de uma rede complexa, consideramos o contorno da imagem como um conjunto de pontos $C = [p_1, p_2, \dots, p_n]$, em que p_i é um vetor de componentes $[x_i, y_i]$ representando cada pixel pertencente ao contorno, onde x_i e y_i são suas coordenadas. Portanto, a rede será construída como um grafo onde cada pixel p_i é um vértice e cada aresta tem peso determinado pela distância euclidiana entre seus vértices, *e.g.*,

$$d(p_i, p_j) = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}. \quad (1)$$

Então obtemos a matriz W de tamanho $N \times N$ onde N representa o número de vértices da rede. A matriz é preenchida com os pesos das arestas calculados, *i.e.*,

$$w_{ij} = W([w_i, w_j]) = d(p_i, p_j). \quad (2)$$

Logo após, os valores da matriz são normalizados no intervalo $[0, 1]$, *i.e.*,

$$W = \frac{W}{\max w_{ij} \in W}. \quad (3)$$

Dessa forma, a rede obtida é um rede regular, pois cada vértice possui uma aresta para todos os outros (grafo completo). De uma rede regular não podemos extrair características interessantes para nossa abordagem, já que ela comporta regularmente, seus vértices tem o mesmo número de conexões. Então, devemos realizar uma transformação na rede de modo a obter um rede complexa. Essa transformação é descrita como o próximo passo para extração de características.

Evolução Dinâmica

Como mostrado na seção anterior, o primeiro passo para o processo de extração de características é transformar a rede regular obtida em uma rede complexa. Então, um processo de evolução dinâmica de acordo com um limiar T_l é construído. A transformação δ é procedida como segue. A cada iteração l , todas as arestas com peso maior que T_l são removidas da rede regular. Então, obtemos uma nova rede complexa a cada iteração l , *i.e.*,

$$A_{T_l} = \delta_{T_l}(W) = \begin{cases} a_{ij} = 0, & \text{if } w_{ij} \geq T_l \\ a_{ij} = 1, & \text{if } w_{ij} \leq T_l \end{cases}. \quad (4)$$

A evolução de cada rede é garantida pelo uso de várias funções δ onde o limiar T_l é incrementado sequencialmente de um valor T_{inc} , como mostrado na Eq. 5: $f : T \rightarrow T$,

$$\begin{aligned} T_0 &= T_{ini} | 0 < T_{ini} < 1, \\ T_{l+1} &= f(T_l) \text{ if } T_l < T_Q < 1, \\ f(x) &= x + T_{inc} \end{aligned} \quad (5)$$

onde T_{ini} e T_Q são os liminares inicial e final, respectivamente. Essas funções definem a evolução dinâmica, com um número finito de variações na rede complexa. A partir dessa evolução, extraímos as características como segue.

Conectividade

A conectividade k_i de um vértice i corresponde ao número de arestas diretamente conectadas a esse vértice, e pode ser obtida através da matriz de adjacência A , *i.e.*,

$$k_i = \sum_{j=1}^N a_{ij}. \quad (6)$$

O primeiro vetor de características extraído para posterior classificação é composto por descritores de conectividade presentes nas diversas transformações da rede T_l . Para cada A_{T_l} obtido, dois valores são calculados que descrevem a conectividade de cada rede, *i.e.*, o grau médio (k_μ) e o grau máximo (k_K) de seus vértices, *i.e.*,

$$k_\mu = \frac{1}{N} \sum_{j=1}^N a_{ij}, \quad (7)$$

$$k_K = \max_i k_i. \quad (8)$$

Como demonstrado por [2], apesar dessas características parecerem simples, podemos torná-las invariantes à rotação e a escala através de pequenos ajustes. A invariância à rotação é obtida pela normalização implementada na matriz W no intervalo $[0, 1]$. De outro lado, a invariância à escala pode ser alcançada por uma normalização de k_i pelo número de vértices (N) que compõem a rede, *i.e.*,

$$\forall k_i = \frac{k_i}{N} \quad (9)$$

Então o vetor de características φ , *i.e.*,

$$\varphi = [k_\mu(T_0), k_K(T_0), k_\mu(T_1), k_K(T_1), \dots, k_\mu(T_Q), k_K(T_Q)]$$

é obtido pela concatenação dos valores de grau médio (k_μ) e grau máximo (k_K) obtidos para cada estágio de evolução da rede utilizando limiar no intervalo $[T_0, T_Q]$.

Joint Degree

Em adição à conectividade, é possível examinar outras características sobre as redes complexas. Podemos utilizar o *joint degree* que determina medidas de correlação entre os graus dos vértices.

Para determinar essas medidas de *joint degree*, devemos conhecer a distribuição de probabilidade $P(k_i, k')_i$. Porém, no nosso método, consideramos $k_i = k'$, como sugerido em [2]. Assim, a distribuição $P(k_i, k_i)_i$ representa a probabilidade de um vértice i de grau k_i estar conectado a outro vértice de mesmo grau. Essa distribuição pode ser calculada a partir do grau de todos os vértices. Dessa forma, é possível determinar a probabilidade de conexão entre um vértice de grau k_i com outro k' analisando a matriz de adjacências.

Sendo assim, as características extraídas sobre o *joint degree* são: entropia, energia, e *joint degree* médio, que são descritas a seguir:

5.1) Entropia: De acordo com [2], a entropia está diretamente relacionada ao grau de ordem ou de desordem em um sistema. O cálculo da entropia pode ser definido como:

$$H = - \sum_{i=1}^N P(k_i, k')_i \log_2 P(k_i, k')_i. \quad (10)$$

5.2) *Energia*: A energia pode ser definida pela seguinte expressão:

$$E = - \sum_{i=1}^N (P(k_i, k'_i))^2. \quad (11)$$

5.3) *Joint Degree Médio*: Essa medida denota a probabilidade média de encontrar dois vértices arbitrários de mesmo grau na rede, considerando todas as possibilidades

$$P = \frac{1}{N} \sum_{i=1}^N P(k_i, k'_i). \quad (12)$$

5.2.2 Descritores de Fourier

A principal ideia desse tipo de descritor é caracterizar o contorno como um conjunto de números que representam o conteúdo de frequência de toda a forma, no caso, do dano do folíolo. Baseado na análise da frequência, é possível selecionar um pequeno conjunto de números (coeficientes de Fourier) que descreve a forma/dano.

Para obter esses coeficientes, inicialmente o dano é descrito pelas coordenadas do contorno, escritas como um número complexo $z(k) = x(k) + jy(k)$, onde $j = \sqrt{-1}$. A aplicação da transformada discreta de Fourier a esses dados resulta em um vetor $F = [F_0, F_1, \dots, F_{N-1}]$ onde N é o número de pontos dos dados e $F_i (i = 0, 1, \dots, N - 1)$ são as componentes da transformada de Fourier. Apenas as magnitudes dos coeficientes de Fourier são usados como características [13].

Utilizar o domínio da frequência para representação de um padrão (dano do folíolo) facilita normalizar o padrão a invariâncias, como translação, escala e rotação. Além disso, uma importante vantagem da transformada de Fourier é que os descritores de Fourier são fortemente imunes ao ruídos [12].

5.2.3 Descritores Wavelet

A transformada wavelet pertence a uma transformação que decompõe o sinal em diferentes níveis. Nesse caso, aplicamos a transformada discreta *wavelet*, representando o dano do folíolo em vários níveis, diferenciando na quantidade dos detalhes. Aplicando *wavelets* às representações do dano, é necessário escolher um número limite de níveis e normalizar os coeficientes para prover invariâncias a translação, escala e rotação.

Os descritores Wavelet são formados na base da representação *wavelet* da sequência original (x_i, y_i) , descrevendo o contorno do dano do folíolo. Essa representação pode ser apresentada na forma:

$$\begin{bmatrix} x(l) \\ y(l) \end{bmatrix} \cong \begin{bmatrix} x_a(l) \\ y_a(l) \end{bmatrix} + \sum_{m=k}^M \begin{bmatrix} x_{dm}(l) \\ y_{dm}(l) \end{bmatrix}, \quad (13)$$

onde $x_a(l)$ e $y_a(l)$ são os sinais de aproximação e $x_d(l)$ e $y_d(l)$ são os sinais de detalhe correspondentes ao l th ponto da sequência.

Os sinais de aproximação são expressados através de funções de escala $\phi_m n$ na forma $x_a(l) = \sum_n a_n \phi_{Mn}(l)$ e $y_a(l) = \sum_n c_n \phi_{Mn}(l)$, onde M é o nível máximo de decomposição e n é o índice de translação. Os sinais de detalhe são expressados através

das funções *wavelet* ψ_{mn} na forma $x_{dm}(l) = \sum_n r_{mn}\psi_{mn}(l)$ e $y_{dm}(l) = \sum_n d_{mn}\psi_{mn}(l)$ onde $m = 1, 2, \dots, M$ significa os níveis de decomposição.

Os descritores Wavelet são construídos com os coeficientes a_n, c_n , representando o sinal de aproximação, e com o conjunto de $r_{mn}d_{mn}$ ($m = 1, 2, \dots, M$), representando os sinais de detalhe de M níveis de decomposição. Esses coeficientes passam por um processo de normalização, o que torna o conjunto de descritores *wavelet* invariantes a escala, translação e rotação.

5.2.4 Descritores de Zernike

Diferente dos descritores de Fourier e Wavelet que são baseados no contorno do dano, esse descritor é baseado na região/área do dano. O objetivo é calcular os momentos Zernike. Segundo [12], momentos são descritores globais de forma, e possuem a mesma vantagem dos descritores de Fourier, a habilidade de discernir e filtrar ruídos. Além disso, os momentos Zernike também são invariantes a rotação, translação e escala.

Os momentos Zernike são a projeção da função da imagem em funções da base ortogonal. Essas funções são polinômios na forma

$$V_{nm}(x, y) = V_{nm}(\rho, \theta) = R_{nm}(\rho)e^{jm\theta}, \quad (14)$$

onde $n - |m|$ é par e $0 \leq |m| \leq n$.

A ordem do polinômio é denotada por n e a repetição por m ; ρ é o tamanho do vetor da origem até o pixel (x, y) ; θ é o ângulo entre o vetor ρ e o eixo x ; e $R_{nm}(\rho)$ é o polinômio radial definido como:

$$R_{nm}(\rho) = \sum_{s=0}^{(n-m)/2} \frac{(-1)^s [(n-s)!] \rho^{n-2s}}{s! \binom{n+|m|}{2} - s! \binom{n-|m|}{s}}. \quad (15)$$

Como m pode ter valores negativos, o polinômio radial usa sua magnitude e assim, o relacionamento inverso é: $R_{n,m}(\rho) = R_{n,-m}(\rho)$.

Esses polinômios formam um conjunto ortogonal completo no interior de um círculo unitário de $x^2 + y^2 = 1$. Para computar os momentos Zernike de uma imagem, o centro da imagem é tomado como a origem e as coordenadas dos pixels são mapeadas para o intervalo do círculo unitário. Os pixels que ficarem fora desse círculo não são utilizados para computação. Enfim, o momento Zernike de ordem n com repetição m para uma função $f(x, y)$ de uma imagem digital que desaparece fora do círculo unitário é:

$$Z_{nm} = \frac{n+1}{\pi} \sum_x \sum_y f(x, y) V_{nm}(\rho, \theta), x^2 + y^2 \leq 1. \quad (16)$$

5.3 Classificação

Uma vez que as características são extraídas, é necessário discriminar as duas classes de agentes danificadores, *i.e.*, coleópteros, lagartas. Para essa função, escolhemos o classificador *Support Vector Machine* (SVM). *Support Vector Machines* (SVMs) [15] são métodos que constroem classificadores através da criação de hiper-planos em um espaço n -dimensional, *i.e.*, desenhando “linhas” em um espaço n -dimensional que são capazes de separar exemplos de diferentes classes. Quando confrontados com problemas não-lineares, SVMs criam um mapeamento entre um conjunto de valores de entrada

(exemplos) e um espaço de características, onde essas classes não-lineares de contorno iniciais são feitas linearmente separáveis por uma transformação (ou mapeamento) do espaço de características. Esse mapeamento é feito por um conjunto de funções matemáticas chamadas *kernels*. Depois de realizar esse mapeamento, SVMs utiliza um algoritmo iterativo de treinamento para minimizar a função de erro.

5.4 Experimentos

A fim de testar e validar nosso método, realizamos experimentos utilizando uma base de dados com 180 amostras de folíolos de soja digitalizadas com resolução de 200 dpi.

Essa base de dados foi avaliada manualmente, gerando uma base de dados *ground-truth* com 1700 imagens de dados, onde 1000 amostras são atribuídas a serem causadas por lagartas e 700 por coleópteros.

SVM com *kernel* de função de base gaussiana radial foi escolhido como ferramenta de classificação. Todos os algoritmos SVM são implementados utilizando o pacote LIBSVM [6].

5.5 Experimentos com os descritores de Fourier, Wavelet e Zernike

O classificador SVM é treinado/testado com o esquema de validação cruzada *leave-k-out*, onde k é o número de danos de cada folha. Nesse caso, os danos da folha são deixados de fora no momento de treinar o SVM e são utilizados apenas no teste.

Foram utilizadas 20 características para cada descritor. As características extraídas dos descritores de Fourier e Zernike não foram suficientes para discernir de qual classe pertencem os danos, ou seja, qual o agente danificador que gerou determinado danos. Com esses descritores, o SVM classificou todos os danos como sendo causados por lagartas, o que significa que ele apresentou sensibilidade zero para a classe dos coleópteros. Já as características do descritor Wavelet apresentaram uma performance superior a 70%.

Esses resultados podem ser melhor visualizados nas Figuras 4(a) e 4(b), onde os danos com cor amarela e azul são de coleópteros e lagartas, respectivamente, e foram classificados corretamente pelo SVM; e os danos com cor verde são da classe dos coleópteros porém foram classificados como danos de lagartas pelo SVM.

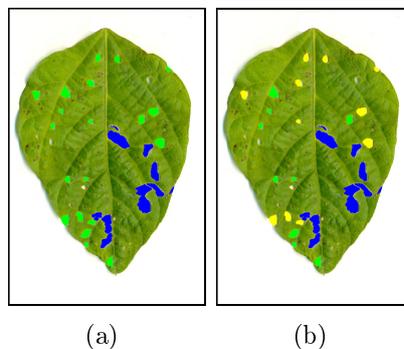


Figura 4: Resultado obtido para uma amostra: (a) Classificação com os descritores de Fourier e Zernike; (b) Classificação com os descritores de Wavelet.

A precisão da classificação e sensibilidade para as classes coléopteros (SenB) e lagartas (SenC) obtidos com essas características são mostrados na Tabela 1.

Fourier			Wavelet			Zernike		
Precisão	SenB	SenC	Precisão	SenB	SenC	Precisão	SenB	SenC
68.31(22.9)	NaN(NaN)	NaN(21.3)	70.91(22.9)	69.8(25.4)	72.1(20.4)	68.31(22.9)	NaN(NaN)	NaN(21.3)

Tabela 1: Precisão para classificação dos agentes danificadores e sensibilidade para as classes coleóptero (SenB) e lagarta (SenC) utilizando diferentes descritores. Os valores em parênteses representam o desvio padrão da precisão para o esquema de validação cruzada.

5.6 Experimentos com os descritores baseados em redes complexas

O conjunto de dados é dividido em 10 partições para treino/teste mantendo as classes balanceadas em cada partição.

Inicialmente, os parâmetros do modelo são selecionados utilizando a validação cruzada *5-fold* em um esquema de busca *grid* e 10% de amostras escolhidas aleatoriamente de nossa base de dados. O valores obtidos para o parâmetro de penalidade para o SVM e o parâmetro de largura para o *kernel* são $C = 5$ e $\gamma = 1/8f$, respectivamente, onde f é número de características utilizadas.

Depois, o classificador SVM é treinado/testado baseado no esquema de validação cruzada *leave-10-fold-out*. Nosso método apresentou precisão maior que 90% para classificação dos agentes danificadores com a utilização do descritor baseado em redes complexas.

Para observar o comportamento dos classificadores para diferentes níveis de modelagem de redes complexas, selecionamos estágios de evolução dinâmica variando T_0 , T_Q , e T_{inc} (e consequentemente o número de características). A precisão da classificação e sensibilidade para as classes coleópteros (SenB) e lagartas (SenC) obtidos pelo método proposto são mostrados na Tabela 2.

Podemos observar que os descritores de conectividade não realizaram bem a tarefa de classificação, enquanto os descritores *joint degree* obtiveram uma taxa de precisão maior que 90%. Essa conclusão não está de acordo com os resultados obtidos em [2]. Nesse outro trabalho, descritores CN foram ligeiramente melhores do que os descritores JD. Além disso, a precisão do método proposto apresentou ser robusto em termos da variação dos limiares.

6 Trabalhos Futuros

Como trabalhos futuros, iremos coletar as avaliações das folhas realizadas por pesquisadores da Universidade Federal de Viçosa, e então realizar os testes novamente. Além disso, pretendemos implementar mais alguns classificadores para comparar com os resultados do SVM e escolher o melhor classificador.

T_0	T_Q	Conectividade									Joint Degree								
		Número de Características																	
		20			40			60			30			60			90		
	Precisão	SenB	SenC	Precisão	SenB	SenC	Precisão	SenB	SenC	Precisão	SenB	SenC	Precisão	SenB	SenC	Precisão	SenB	SenC	
0.05	0.60	65.4(1.7)	57.8	71.2	65.9(4.2)	58.0	72.2	66.1(3.0)	58.2	72.2	91.0(1.7)	90.0	91.8	90.6(2.7)	89.5	91.4	88.8(1.8)	88.6	89.0
0.05	0.80	65.6(3.6)	60.5	68.6	65.9(1.8)	60.1	69.2	65.8(3.4)	60.6	68.8	91.5(1.9)	90.1	92.3	90.8(2.6)	90.0	91.4	90.9(2.4)	90.2	91.4
0.05	0.90	65.3(2.0)	61.5	67.8	65.6(3.8)	59.7	68.7	66.0(3.8)	61.0	68.7	91.3(1.6)	90.0	92.4	90.7(2.6)	89.7	91.4	90.4(2.2)	90.3	90.3
0.05	0.95	64.5(2.1)	59.7	66.8	65.5(2.3)	60.1	68.9	65.9(4.4)	61.0	68.4	91.4(1.6)	89.5	92.9	90.7(1.4)	89.3	91.6	90.2(2.1)	90.7	89.9
0.10	0.60	65.3(4.3)	57.6	71.2	65.4(3.7)	57.5	71.9	65.6(2.2)	57.7	72.0	90.5(2.5)	89.7	90.9	90.7(2.1)	90.5	90.7	89.6(3.1)	87.7	91.0
0.10	0.80	65.5(3.1)	59.4	68.6	65.9(3.3)	60.1	69.1	65.8(4.0)	60.1	68.8	92.1(2.7)	91.9	92.3	91.5(2.2)	91.1	91.9	91.0(2.4)	90.6	91.3
0.10	0.90	65.6(4.4)	60.4	68.5	65.8(4.0)	59.8	69.2	65.8(4.1)	61.0	68.5	91.4(1.3)	91.2	91.6	92.1(1.7)	91.3	92.6	92.2(1.8)	92.5	92.1
0.10	0.95	66.1(3.1)	61.4	68.5	66.1(2.2)	60.7	69.2	66.2(4.1)	61.5	68.6	91.4(2.1)	89.8	92.6	91.2(2.3)	90.7	91.5	91.3(2.2)	91.3	91.3
0.15	0.60	65.1(2.2)	57.2	71.3	65.8(4.2)	57.7	72.2	65.7(4.0)	57.7	72.2	90.8(1.5)	92.1	90.1	90.5(2.8)	91.8	89.9	90.7(1.6)	91.5	90.2
0.15	0.80	65.9(4.3)	60.4	68.8	65.2(3.8)	59.3	68.7	65.9(5.4)	60.1	69.1	91.5(2.5)	91.7	91.5	91.1(1.4)	90.8	91.3	90.8(2.0)	90.6	90.9
0.15	0.90	65.9(3.4)	61.7	68.7	65.8(2.9)	60.1	69.0	65.7(3.0)	60.4	68.7	91.5(1.4)	91.0	91.8	91.8(1.7)	91.4	92.2	91.2(2.4)	91.0	91.2
0.15	0.95	65.9(3.6)	60.6	68.5	66.0(2.4)	60.1	69.2	65.9(3.0)	60.5	68.7	91.5(1.7)	90.2	92.3	92.1(1.7)	91.5	92.4	90.8(1.9)	89.7	91.5
0.20	0.60	65.6(2.4)	57.8	71.8	65.8(3.8)	58.0	72.0	65.6(3.8)	57.9	72.3	90.1(1.5)	92.4	88.6	89.2(2.7)	92.3	87.5	89.2(2.1)	91.9	87.8
0.20	0.80	65.9(3.9)	60.0	69.1	65.5(3.4)	59.6	68.9	66.1(2.6)	60.1	69.1	91.3(2.1)	91.3	91.4	90.7(1.9)	90.4	91.0	90.7(1.7)	90.7	90.7
0.20	0.90	65.5(4.5)	59.9	68.4	65.8(3.7)	59.6	69.2	65.7(3.0)	60.8	68.7	91.8(1.7)	91.8	91.9	92.5(2.3)	92.1	92.8	91.1(2.4)	90.9	91.3
0.20	0.95	65.9(4.1)	61.0	68.7	65.7(2.4)	60.1	68.8	66.0(3.1)	60.4	69.0	92.5(2.7)	92.2	92.6	92.5(2.0)	91.8	92.9	91.7(3.1)	91.1	92.1

Tabela 2: Precisão para classificação dos agentes danificadores e sensibilidade para as classes coleóptero (SenB) e lagarta (SenC) utilizando diferentes valores T_i . Os valores em parênteses representam o desvio padrão da precisão para o esquema de validação cruzada *10-fold*.

7 Cronograma de atividades

A Tabela 3 mostra o cronograma com as atividades a serem realizadas, começando em Março de 2011, e terminando em Julho de 2011.

Atividades	Ago	Set	Out	Nov	Dez
Coletas avaliações dos especialistas	X	X			
Implementar outros classificadores	X	X			
Refazer os testes			X	X	
Redigir a Monografia			X	X	X
Apresentação do Trabalho					X

Tabela 3: Cronograma de Atividades.

Referências

- [1] L. Antigueira, M. G. V. Nunes, O. N. Oliveira, and L. F. Costa. Strong correlations between text quality and complex networks features. *Physica A*, 373(1):811–820, 2007.
- [2] A. R. Backes, D. Casanova, and O. M. Bruno. A complex network-based approach for boundary shape analysis. *Pattern Recognition*, 42(1):54–67, 2009.
- [3] Kale D. M. Eapen-S. Murty G. S. S Badigannavar, A. M. Inheritance of disease lesion mimic leaf trait in groundnut. *The Journal of Heredity*, 93(1):50–52, 2002.
- [4] C. M. Bishop. *Neural Networks for Pattern Recognition*. Oxford University Press USA, 1996.
- [5] T. Chalumeau, L. F. Costa, O. Laligant, and F; Meriaudeau. Texture discrimination using hierarchical complex networks. In *International Conference on Signal-Image Technology and Internet-Based Systems*, pages 543–550, 2006.
- [6] C-C. Chang and C-Jen Lin. Libsvm: a library for support vector machines. <http://www.csie.ntu.edu.tw/~cjlin/libsvm>, 2001.
- [7] Hart P. E. Stork-D. G. Duda, R. O. *Pattern Classification*. Wiley-Interscience, 2000.
- [8] R. C. Gonzalez and R. E. Woods. *Digital Image Processing*. Prentice Hall, 3rd ed edition, 2007.
- [9] R. C. Gonzalez and R. E. Woods. *Digital Image Processing*. Prentice Hall, 3 edition, 2008.
- [10] Souza E. L. C. Maringoni, A. C. Reação de cultivares de soja isolado de *Curatobacterium flaccumfaciens pv. flaccumfaciens*, proveniente de feijoeiro. *Pesquisa Agropecuária Brasileira*, 38(6), 2003.
- [11] A. C. Nazaré-Jr, D. Menotti, J. M. R. Neves, and T. Sedyama. Automatic detection of the damaged leaf area in digital images of soybean. In *International Conference on Systems, Signals and Image Processing (IWSSIP)*, pages 499–503. IEEE, 2010.
- [12] M. Nixon and A. Aguado. *Feature Extraction & Image Processing*. Elsevier, second edition, 2008.
- [13] S. Osowski and D. D. Nghia. Fourier and wavelet descriptors for shape recognition using neural networks - a comparative study. In *Pattern Recognition 35*, pages 1949–1957, 2002.
- [14] Schwartz W. R. Pedrini, H. *Análise de Imagens Digitais*. Thomsom, 1 edition, 2008.
- [15] B. Scholkopf and A. J. Smola. *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*. The MIT Press, 2002.

- [16] T. Sedyama. *Tecnologias de produção e usos da soja*. MECENAS, 2009.
- [17] Alves E. De-Castro H. A. Sousa, P. F. C. Influência da temperatura no desenvolvimento de *teliosporos* de *Phakopsora pachyrhizi* em folíolos de soja. *Summa phytopathol*, 38(6), 2006.
- [18] T. L. G. Souza, S. S. Almeida, and D. Menotti. Caracterização automática de danos em folíolos de soja. 2011.
- [19] T. L. G. Souza, E. S. Mapa, K. dos Santos, and D. Menotti. Application of complex networks for automatic classification of damaging agents in soybean leaflets. In *International Conference of Image Processing (ICIP)*. IEEE, 2011. aceito para publicação.
- [20] Domingues R. J. Tófoli, J. G. Doenças da cenoura: queima das folhas por alternária e cercóspora. In *Revista Cultivar*, 2005.
- [21] D. J. Watts and S. H. Strogatz. Collective dynamics of 'small-world' networks. *Nature*, 393(6684):440–442, 1998.