

# Aplicação de redes complexas na classificação automática de agentes danificadores em folíolos de soja

Eduardo Severino Mapa, Kayran dos Santos, Thiago Luis Guimarães de Souza e David Menotti

Departamento de Computação - Universidade Federal de Ouro Preto

Campus Universitário, Morro do Cruzeiro, CEP 35400-000, Ouro Preto, Minas Gerais, Brasil

eduardomapa@gmail.com, kayransantos2@gmail.com, thiagoluis13@gmail.com, menottid@gmail.com

## Abstract

*Grande parte das dificuldades de manejo em culturas de soja está relacionada à detecção do inseto-praga nocivo aos cultivares, visto que essa cultura está sujeita a ataques de uma ampla gama de pragas. Com a identificação das ocorrências mais comuns dos agentes causadores de dano aos folíolos (e.g. coleópteros, lagartas, etc.), é possível obter maior conhecimento sobre estratégias adequadas de controle. O trabalho proposto desenvolve um método automático de classificação dos principais agentes causadores de lesões em folíolos. As imagens adquiridas são pré-processadas e os contornos dos danos extraídos. Cada um dos contornos será modelado com uso de Redes Complexas. A conectividade das redes é medida para compor os vetores de características discriminantes entre estes danos. Após obtenção das características o classificador é treinado por meio de uma LDA (Linear Discriminant Analysis) e validado na avaliação das amostras.*

## Abstract

*Many of the difficulties in managing soybean crops are related to the identification of insect/pests harmful to the cultivars, since crops can be attacked by a wide range of such agents. By identifying the most common agents that cause damage to the leaves (e.g., beetles, caterpillars, etc.), we get more knowledge about appropriate strategies of control. The proposed work develops an automatic classification method of the main agents that cause damage to leaves. Acquired images are preprocessed and the contours of the damage taken. Each one of the contours will be modeled by complex networks. The network connectivity is measured to compose the feature vectors which discriminates these damages. Obtained features are used to train the classifier using LDA and validated in sample evaluations.*

## 1. Introdução

O controle de pragas em culturas de soja consiste em um sistema de tomada de decisões em consequência a ação de diferentes tipos de insetos-pragas em cultivares, bem como da frequência com que ocorre cada um destes agentes.

Na maioria dos casos a escolha da medida de controle ocorre de maneira não planejada, geralmente pelo uso excessivo de produtos químicos, o que segundo Picanço & Guedes *et al.* [11], acarreta em prejuízos, poluição ao meio ambiente e intoxicação ao homem.

A identificação das ocorrências mais comuns (e.g. coleópteros, lagartas, etc.), em conjunto com a determinação da frequência com que cada agente ocorre em folíolos, favorece a escolha de uma estratégia eficiente de controle. Segundo [10], os métodos atuais de identificação e frequência de amostragem baseiam-se na técnica do pano de batida. Um método manual, em que se estende um pano entre duas fileiras paralelas de cultivares, logo após, inclinam-se as plantas de modo que os insetos caiam sobre o pano. Para efeito de amostragem, esses insetos serão identificados e contabilizados afim de estimar a razão em que ocorre cada um destes agentes. Com isto a técnica do pano de batida demonstra-se um método de baixa taxa de amostragem e dispendioso em relação ao tempo.

De acordo com as orientações dos especialistas em fitotecnia da UFV demonstradas em [12], observa-se a possibilidade de distinção entre as duas principais classes de agentes (e.g. coleópteros, lagartas), por meio da forma (contorno, área, etc.) dos danos provocados por cada um deles sobre os folíolos, observando-se apenas a parte frontal do folíolo como exemplificam as Figuras 1(a) e 1(b).

Na literatura atual, existem técnicas de classificação automática relacionadas a patologias dos cultivares, tanto em culturas de soja quanto em culturas diversificadas, citadas pelos autores [3] e [4]. Porém não se encontra nenhum método acerca da caracterização das pragas que agem sobre estas culturas.

Este trabalho descreve o desenvolvimento de um método




Figure 1. Recortes em folíolos de soja: (a) Dano atribuído a um coleóptero; (b) Dano atribuído a uma lagarta.

de classificação automática desses agentes por meio de imagens digitais, e irá complementar outro método proposto em [8] de detecção e quantificação automática da área foliar danificada da soja. Isto tornará viável a escolha de uma estratégia de controle eficiente, que reduzirá prejuízos financeiros e ao meio ambiente, causados pelo excessivo uso de defensivos agrícolas.

A seção seguinte irá detalhar a metodologia desenvolvida, desde aquisição e pré-processamento das amostras (2.1, passando pela modelagem de contornos e extração de características com utilização de redes complexas (2.2) até a etapa de classificação por meio de uma LDA (*Linear Discriminant Analysis*).

## 2. Metodologia

### 2.1. Aquisição e pré processamento de imagens

Com auxílio dos pesquisadores do Campo Experimental Bacuri (UFV) obtivemos cerca de 180 amostras de folíolos de diversos cultivares de soja, as quais foram digitalizadas através de *scanner* e armazenadas em arquivos formato *bitmap* (bmp), com resolução de 200 dpi (*"Dots per inch"* - pontos por polegada).

Para realce das regiões correspondentes aos danos nas imagens dos folíolos, foi necessário um pré-processamento das amostras a serem avaliadas, realizado por meio da adaptação de duas técnicas apresentadas por Nazaré-Jr [8].

A primeira consiste na remoção da sombra da imagem, através de uma conversão do espaço de cores RGB (R-red, G-green, B-blue) para o sistema de cores HSV (H-hue, S-saturation, V-value). De acordo com Nazaré-Jr *et al.* [8], ao convertermos a imagem para o espaço de cores HSV, somente o valor do canal H (*hue*) é suficiente para detecção e eliminação da região que representa a sombra da folha na imagem.

A segunda etapa de pré-processamento será a eliminação de resíduos externos aos folíolos adquiridos durante a digitalização da imagem. Esta técnica pode ser subdividida em três passos:

- 1) *Segmentação da Imagem*: a segmentação utilizada consiste em detectar um limiar adequado por meio do algoritmo de Otsu [7], que definirá a região de interesse (o próprio folíolo). O restante da amostra será considerado como fundo, de modo que o resultado desta segmentação será uma imagem, em que toda região considerada como fundo terá *pixels* de cor branca ( $R = G = B = 255$ ), e a região de interesse *pixels* de cor preta ( $R = G = B = 0$ ). Porém a imagem ainda possuirá resíduos externos a folha, como mostra a Figura 2.
- 2) *Remoção de Resíduos*: Após a segmentação o seguinte passo será aplicarmos um algoritmo de rotulação [9]. Isto irá determinar a maior região conexa dentro da imagem segmentada. Basta então descartarmos todas as outras regiões e dessa forma todos os resíduos externos a folha serão removidos, o resultado deste passo pode ser observado na Figura 3.




Figure 2. Resultado do passo 1 - Segmentação da Imagem




Figure 3. Resultado do passo 2 - Remoção de Resíduos

- 3) *Segmentação dos danos*:

De posse da imagem 4 que representa a folha reconstituída, isto é, sem danos, iremos segmentar os danos por meio da interseção entre a imagem obtida no passo 2 e a imagem 4 porém com seus níveis invertidos. Como mostra 5:




Figure 4. Imagem da folha reconstituída



Figure 5. Resultado do passo 3 - Segmentação dos Danos

#### 4) Descartar danos menores que 0,02% do folíolo:

Com o intuito de reduzir a quantidade de danos que julgamos serem menos expressivos durante a avaliação, decidimos que danos menores que 0,02% da imagem não serão considerados. O método utilizado para descartar estes danos consiste em identificar os objetos

(danos) que possuem menos de 0,02% de seu tamanho em relação à imagem e aplicar aos seus *pixels* a cor branca ( $R = G = B = 255$ ) de modo que passem a fazer parte do fundo da imagem.

#### 5) Detectar borda do dano:

De acordo com Canny [5], o processo de detecção de bordas serve para simplificar a análise das imagens, reduzindo drasticamente a quantidade de dados a serem processados, enquanto ao mesmo tempo preserva a informação útil sobre os limites da estrutura do objeto. Aplicando o algoritmo detector de bordas (contorno) proposto por Canny [5] nas amostras dos folíolos após a etapa de *Descartar danos menores que 0,02% do folíolo*, será detectado as bordas (contornos) dos danos. Este resultado pode ser observado na Figura 6, os quais serão utilizados na etapa de pré-processamento de separação dos danos.




Figure 6. Resultado do passo 5: Detecção do contorno dos danos

#### 6) Separar danos

Nesta etapa do pré-processamento, cada dano localizado na Figura 6, será separado de forma que, cada um seja individualmente uma imagem representando um dano. Após a etapa *Detectar borda do dano*, cada objeto (dano) é selecionado. Em seguida, é aplicado o método que eliminará a área externa do objeto, tal método detecta a posição mínima e máxima na horizontal e na vertical que o objeto possui e subtrai da imagem original, desta forma, uma nova imagem recortada é originada com as dimensões do dano.

## 2.2. Modelagem de contornos por redes complexas

### 2.2.1 Redes Complexas

Segundo [2] a área de Redes Complexas pode ser vista como uma interseção de duas outras importantes áreas, teoria dos grafos e estatística.

Na literatura atual podemos encontrar aplicações de redes complexas nos mais diversos ramos em ciência da computação, como exibem [1] e [6] que modelam textos e imagens de textura por meio de redes complexas. Neste trabalho utilizamos esta abordagem durante a modelagem dos contornos das formas que serão classificadas, assim como aplica [2] que também modela contornos desta maneira para classificação de imagens.

A modelagem apresentada em [2] é baseado no modelo de rede Watts-Strogatz [13]. Este modelo possui duas propriedades interessantes, a primeira é que todos os seus vértices podem ser alcançados por qualquer outro com um número pequeno de arestas, a segunda está na grande quantidade de ciclos mínimos (ou seja tamanho 3) que são formados. Essas propriedades são definidas como propriedades de mundo pequeno.

Para extração de características realiza-se uma evolução dinâmica gerada através de um crescimento da rede limitado por um limiar sequencial.

### 2.2.2 Construção da Rede Complexa

A fim de modelarmos o contorno de uma imagem 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 construído como um grafo em que cada pixel ( $p_i$ ) será um vértice e cada aresta terá seu peso determinado pela distância euclidiana entre seus vértices, calculada em 1.

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

Obteremos então uma matriz  $W$  de tamanho  $N \times N$  em que  $N$  representa o número de vértices da rede, a matriz será preenchida com os pesos das arestas já calculados, como pode ser visto em 2:

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

Logo após os valores da matriz serão normalizados pela equação 3 no intervalo  $[0, 1]$ .

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

Desta forma a rede obtida se trata de uma rede regular, pois cada vértice possui uma aresta para todos os out-

ros (grafo completo). Uma rede regular não possui nenhuma característica interessante a nossa abordagem, devemos então realizar uma transformação de modo a tornar esta rede complexa, esta transformação será descrita a seguir durante a etapa de extração de características.

### 2.2.3 Evolução Dinâmica

Como mostra a seção anterior, o primeiro passo para o processo de extração de características é transformar a rede regular obtida em uma rede complexa, para isso será então definido um processo de evolução dinâmica segundo um limiar  $T_l$ . A transformação  $\delta$  procederá da seguinte maneira, a cada iteração  $l$  serão removidas todas as arestas da rede regular cujo peso for maior que  $T_l$ .

Será obtida então uma matriz de adjacência  $A$  que irá determinar para cada aresta da rede regular, se ela existirá ( $a_{ij} = 1$ ) ou não ( $a_{ij} = 0$ ) na nova rede gerada. Portanto, os valores  $a_{ij}$  da matriz  $A$  serão preenchidos segundo a equação 4:

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

A evolução da rede será garantida então pelo uso de várias funções  $\delta$  onde o limiar  $T_l$  será incrementado sequencialmente de um valor  $T_{inc}$ , como mostra a função 5  $f : T \rightarrow T$ , onde

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

com  $T_{ini}$  e  $T_Q$ , os limiares inicial e final respectivamente. Com essas duas funções é definido a evolução dinâmica, com um número finito de variações na rede complexa de onde serão extraídas as características que descreveremos a seguir.

### 2.2.4 Conectividade

A conectividade  $k_i$  de um vértice  $i$  corresponde ao número de arestas diretamente conectadas a esse vértice, e pode ser obtido por meio da matriz de adjacência  $A$  pela expressão 6:

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

O primeiro vetor de características extraído para posterior classificação, será então composto por descritores de conectividade presentes nas diversas transformações da rede  $T_l$ . Para cada matriz  $A_{T_l}$  obtida serão calculados dois valores que descrevem a conectividade de cada rede, o grau

médio ( $k_\mu$ ) e o grau máximo ( $k_K$ ) de seus vértices, por meio das equações 7 e 8 respectivamente.

$$k_K = \max_i k_i \quad (7)$$

$$k_\mu = \frac{1}{N} \sum_{j=1}^N a_{ij} \quad (8)$$

Como demonstra [2], apesar de serem simples estas características possibilitam invariância a rotação e a escala por meio de pequenos ajustes. A invariância a rotação será obtida pela normalização já realizada sob a matriz  $W$  no intervalo  $[0,1]$ . Já a invariância a escala pode ser alcançada por uma normalização de  $k_i$  pelo número de vértices ( $N$ ) que compõem a rede, como mostra 9.

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

O vetor de características  $\varphi$  exibido a seguir, será obtido então pela concatenação dos valores de grau médio ( $k_\mu$ ) e grau máximo ( $k_K$ ) obtidos para cada estágio de evolução da rede, com o limiar no intervalo de  $[T_0, T_Q]$ .

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

### 2.3. Classificação

Para classificar os danos como danos de coleópteros e lagartos foi utilizado o classificador linear LDA.

O LDA procura a melhor reta de separação dos dados de forma que aumente a distância entre classes e diminua a distância intra classe.

O LDA calcula os centroides das classes ( $\mu_i$ ) e o centroide global ( $\mu$ ). O cálculo dos centroides é feito calculando a média sobre os vetores de características. Os vetores de características são os graus máximo e médio de conectividade da rede dado um limiar. Tendo os centroides locais, os dados são normalizados subtraindo-os. Em seguida a matriz de covariância de cada classe é calculada para os dados normalizados. Depois a matriz de covariância conjunta é calculada utilizando as matrizes de covariância das classes e as respectivas probabilidades a priori. Tendo esta matriz é calculada a inversa da matriz de covariância ( $C^{-1}$ ). Com isso podemos calcular a função discriminante para cada classe. Essa função é calculada pela fórmula:

$$f_i = \mu_i C^{-1} x_k^T - \frac{1}{2} \mu_i C^{-1} \mu_k^T - \ln(p_i) \quad (10)$$

A classe do dano a ser classificado é aquela que a função discriminante é maximizada dado o vetor de características ( $x_k^T$ ) do dano.

## 3. Experimentos

Para execução de experimentos foi utilizada uma base de 180 imagens de folíolos de soja, préprocessadas utilizando os métodos mostrados na subseção 2.1. Todos os danos extraídos foram salvos em imagens gerando uma base de 1700 danos.

Os danos extraídos foram classificados manualmente pelos autores para o aprendizado supervisionado como sendo danos de coleópteros ou lagartas. Essa classificação gerou uma base de 1000 danos causados por lagartas e 700 danos causados por coleópteros. Nas figuras 7 e 8 são exibidos danos atribuídos a coleópteros e lagartas, presentes na figura 6.




Figure 7. Imagem ampliada e fora de escala, de danos atribuídos a coleópteros.




Figure 8. Imagem ampliada e fora de escala, de danos atribuídos a lagartas

Para validação dos testes foi utilizada Validação Cruzada (*K-Fold Cross Validation*), onde nossa base foi separada em 10 partições, cada partição continha 170 imagens de danos, sendo 100 imagens de danos de lagartas e 70 de danos de coleópteros. foram feitas 10 iterações, a cada iteração uma partição diferente era separada. A partição separada foi utilizada em testes e as demais foram utilizadas no treinamento do sistema.

Os experimentos executados obtiveram precisão de classificação de 76, 82%. A taxa elevada de erro de 23, 18%

pode ser explicada pois a supervisão do sistema não foi feita por especialistas na área, portanto que muitos danos podem ter sido erroneamente classificados como danos de lagartas ou coleópteros. Com a avaliação supervisionada pelos especialistas da UFV espera-se um aumento da precisão do sistema.

#### 4. Conclusão

O uso de redes complexas, permite modelar diversas aplicações que utilizam classificação por contorno de formas, porém na literatura atual, não se encontra nenhuma abordagem que visa classificar agentes causadores de danos em folíolos de soja. Com isto a abordagem descrita consiste na adaptação da modelagem por redes complexas, sobre os contornos dos danos, de modo a extrair características suficientes para discriminar a ocorrência dos agentes.

Como a supervisão do treinamento foi baseada em uma avaliação dos próprios autores, que não possuem conhecimentos na área de fitotecnia, os resultados não foram satisfatórios, porém devemos considerar que uma supervisão por especialistas poderá elevar a precisão do classificador. Considerando ainda este trabalho como abordagem inicial para o nosso problema, poderemos revisar o classificador utilizado ou optar por um outro mais robusto de modo a melhorar a taxa de acerto obtida.

#### References

- [1] L. Antiqueira, M. d. G. V. Nunes, O. Oliveira, and L. d. F. Costa. Strong correlations between text quality and complex networks features, 2005. <http://arxiv.org/abs/physics/0504033>.
- [2] A. R. Backes, D. Casanova, and O. M. Bruno. A complex network-based approach for boundary shape analysis. *Pattern Recognition*, 2009.
- [3] A. Camargo and J. S. Smith. Image pattern classification for the identification of disease causing agents in plants. *Computers and Electronics in Agriculture*, 66:121–125, 2009.
- [4] A. Camargo and J. S. Smith. An image-processing based algorithm to automatically identify plant disease visual symptoms. *Biosystems Engineering*, 102:9–21, 2009.
- [5] J. Canny. A computational approach to edge detection. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 8:679–714, 1986.
- [6] T. Chalumeau, L. d. F. Costa, O. Laligant, and F. Meriaudeau. Texture discrimination using hierarchical complex networks. In *Proceedings of the Second International Conference on Signal-Image Technology and Internet-Based Systems*, pages 543–550, 2006.
- [7] R. C. Gonzalez and R. E. Woods. *Digital Image Processing*. Prentice Hall, 3a. edição edition, 2008.
- [8] A. C. Nazaré-Jr, D. G. Menotti, J. M. R. Neves, and T. Sedyama. Detecção automática da Área foliar danificada da soja através de imagens digitais. In *WUW-SIBGRABI 2009*, pages 1–8, 2009.
- [9] H. Pedrini and W. R. Schwartz. *Análise de Imagens Digitais*. Thomson, São Paulo, 1a. edição edition, 2008.
- [10] M. C. Picanço, F. L. Fernandes, E. G. F. Moraes, M. R. Campos, and V. M. Xavier. *Tecnologias de Produção e Usos da Soja*, chapter Manejo Integrado das Pragas, pages 119–132. Mecenias, Londrina, 2009.
- [11] M. C. Picanço and R. N. C. Guedes. Manejo integrado de pragas no brasil: situação atual, problemas e perspectivas. *Ação Ambiental*, 2(4):23–26, 1999.
- [12] T. L. G. Souza, D. G. Menotti, J. M. R. Neves, and T. Sedyama. Desenvolvimento de uma interface online de avaliação manual em rumo a um método automático de caracterização dos agentes causadores de lesões em folíolos de cultivares de soja. In *WUW-SIBGRABI 2010*, pages 1–5, 2010.
- [13] D. Watts and S. Strogatz. Collective dynamics of 'small-world' networks. *Nature*, 393:440–442, 1998.