

**Resumo do Estado da Arte: Caracterização  
Automática dos Agentes Causadores de Lesões em  
Folíolos de Cultivares do Brasil**

Autores:  
Thiago L. G. Souza  
Kayran dos Santos

Ouro Preto  
7 de setembro de 2010

# Sumário

<b>1</b>	<b>Introdução</b>	<b>1</b>
<b>2</b>	<b>Abordagens Atuais</b>	<b>1</b>
2.1	Classificação Baseada na Similaridade das Formas . . . . .	1
2.2	Classificação por meio de redes complexas . . . . .	2
2.3	Classificação com aplicação de algoritmos genéticos . . . . .	2
2.4	Outras abordagens . . . . .	3
<b>3</b>	<b>Conclusões</b>	<b>3</b>

# 1 Introdução

O tema que abordamos na disciplina de Reconhecimento de Padrões, é Caracterização Automática dos Agentes Causadores de Lesões em Foliolos de Cultivares do Brasil.

Tendo um conhecimento prévio adquirido por meio de uma integração com especialistas em fitotecnia da Universidade Federal de Viçosa, foi constatada a possibilidade de discriminação entre os principais agentes (*e.g.* coleópteros, lagartas, *etc.*), com as diferentes formas de dano que cada um deles causa sobre os folíolos de soja, incluindo características como: área, contorno, entre outros. Como exemplificam as Figuras 1(a) e 1(b).

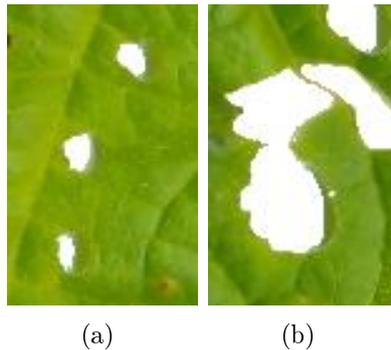


Figura 1: Recortes em folíolos de soja: (a) Dano atribuído a um coleóptero; (b) Dano atribuído a uma lagarta.

Sendo assim, nosso problema requer um estudo sobre as técnicas de reconhecimento de padrão necessárias a classificação das diferentes formas de danos que podem ser encontradas nas amostras.

Porém na literatura atual não se encontra nenhum trabalho que trata especificamente deste assunto (classificação de danos em folíolos). Durante esta revisão de literatura serão então apresentados nas seções seguintes trabalhos que utilizam alguns dos principais métodos de reconhecimento e classificação de formas em diversas aplicações com intuito de adequar algumas delas à abordagem do nosso problema.

## 2 Abordagens Atuais

A seguir descreveremos as abordagens atuais aplicadas no reconhecimento e classificação de formas. Dentre elas algumas podem ser adequadas ao nosso contexto, tendo como referência os artigos obtidos durante a revisão de literatura, os quais são citados neste trabalho.

### 2.1 Classificação Baseada na Similaridade das Formas

O passo inicial desta abordagem consiste na extração da borda do objeto de interesse.

Tendo seu contorno definido, o passo seguinte será extrair características definidas pela borda que possam estabelecer critérios de similaridade entre as classes a serem classificadas.

Como cita [1], uma dessas características pode ser definida através da soma das distâncias entre o centro de massa e os pontos localizados na borda do objeto.

Após definido um critério de classificação entre as classes de interesse, são extraídas partes menores das bordas por meio de uma evolução de curva discreta, que irão ressaltar o grau de similaridade de uma das classes, o que ilustra [2]. Constrói-se então um conjunto de imagens que contem estas partes menores as quais serão comparadas no processo de classificação de uma amostra, garantindo invariância a escala, rotação e translação.

Em [3], que trabalha com reconhecimento de folíolos, além do contorno outra característica que atribui maior precisão a similaridade, é disposição das nervuras no folíolo, desta formas mais características são acrescentadas durante a definição de uma classe, tornando mais robusta o reconhecimento de uma delas uma delas.

## 2.2 Classificação por meio de redes complexas

As abordagens que se baseiam no uso de redes combinam algoritmos evolutivos que se aprimoram dinamicamente durante o treinamento de um *perceptron* de multicamadas aplicados geralmente em uma rede neuronal, como em [4].

Ou então podem partir da representação do contorno de uma forma por uma rede complexa (Figura 2) para então realizar posterior análise de seu grau de complexidade e evolução dinâmica sobre esta rede, como ilustra [5].

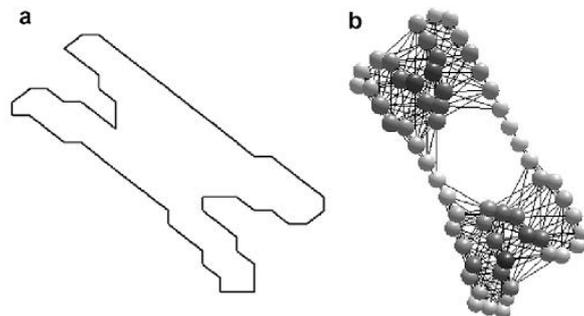


Figura 2: Exemplo de um contorno modelado por uma rede complexa

Em ambos os trabalhos encontrados, os métodos foram avaliados no reconhecimento de folíolos de espécies vegetais distintas, os resultados observados revelam sua robustez perante a escala, rotação e translação comparado a métodos clássicos de reconhecimento.

## 2.3 Classificação com aplicação de algoritmos genéticos

Nos trabalhos que se referem ao uso de algoritmos genéticos no processo de reconhecimento de formas, observamos a aplicação destes algoritmos durante a etapa de *matching* de modo que o algoritmo, partindo de características já extraídas sobre as classes de imagens, possa associar mais precisamente as similaridades entre duas imagens.

Durante representação destas características podem ser adotadas diversas maneiras, como no caso [6], todo o contorno da forma é representado através de um

grafo, e assim de acordo com a angulação de seus segmentos/curvas, é dado um peso para as arestas que ligam seus vértices. O *matching* é então realizado pela comparação de dois grafos.

Já em [7], que trabalha com imagens médicas as características são previamente extraídas e posteriormente serão gerados *templates*, que definem cada uma das classes e serão comparados durante o *matching*.

Assim como em abordagens anteriores estes métodos também são avaliados em conjuntos extensos de amostras, demonstrando eficiência e invariância a escala, rotação e translação.

## 2.4 Outras abordagens

Além das já citadas, encontramos ainda uma série de abordagens com bom nível de eficiência em reconhecimento de formas, porém ilustradas com menos publicações, iremos apresentá-las brevemente nesta subseção, citando pelo menos um trabalho no qual ela está presente.

- Reconhecimento baseado em *kernel-edit distance*: *edit-distance* pode ser vista como uma medida de similaridade, que determina a o número de operações necessárias para transformar um objeto em outro, desta forma o trabalho [8] ilustra o reconhecimento de formas pelo uso desta medida.
- Reconhecimento por representação simbólica: nesta abordagem o contorno de uma forma é representado através de uma simbologia que garante invariância e robustez na extração de características do método como pode ser observado em [9].
- Classificação pelo esqueleto da forma: os trabalhos [10] e [11] demonstram uma abordagem em que o processo de *matching* se dá pelo esqueleto da forma, onde são realizados alguns procedimentos a fim de evitar variância quanto a rotação e translação.
- Forma adaptativa e segmentação variacional: no trabalho [12] ocorre o reconhecimento de caracteres em manuscritos históricos, o método utilizado por ele se baseia, em modelos pré-estabelecidos de caracteres já conhecidos, que se adaptam durante as etapas de segmentação e *matching*.
- Classificação pelo uso da Equação de *Poisson*: aplicando-se a equação de *Poisson*, sobre a silhueta de um objeto, teremos como resultado uma função que irá determinar para cada ponto interno na silhueta, o tempo gasto para caminhar até um ponto da borda, com isto este método também se torna um eficiente descritor de características para algumas classes de objetos, como exemplifica [13].

### 3 Conclusões

Durante esta revisão de literatura, foram apresentadas as principais abordagens que compõem o estado-da-arte atual referente ao reconhecimento de formas em suas diversas aplicações.

Como proposta de desenvolvimento seguinte, fica a implementação de alguns dos métodos apresentados a fim de realizar a adequação ao contexto de nosso problema, que se dará durante a disciplina de Reconhecimento de Padrões.

## Referências

- [1] E. Attalla and P. Siy, “Robust shape similarity retrieval based on contour segmentation polygonal multiresolution and elastic matching,” in *Pattern Recognition*, 2005, pp. 2229–2241.
- [2] X. Bai, X. Yang, and L. J. Latecki, “Detection and recognition of contour parts based on shape similarity,” in *Pattern Recognition*, 2007, pp. 2189–2199.
- [3] Y. Nam, E. Hwang, and D. Kim, “A similarity-based leaf image retrieval scheme: Joining shape and venation features,” in *Computer Vision and Image Understanding*, 2008, pp. 245–259.
- [4] J. Du, D. Huang, X. Wang, and X. Gu, “Shape recognition based on neural networks trained by differential evolution algorithm,” in *Neurocomputing*, 2007, pp. 896–903.
- [5] A. R. Backes and O. M. Bruno, “Shape classification using complex network and multi-scale fractal dimension,” in *Pattern Recognition Letters*, 2009, pp. 44–51.
- [6] S. Auwatanamongkol, “Inexact graph matching using a genetic algorithm for image recognition,” in *Pattern Recognition Letters*, 2007, pp. 1428–1437.
- [7] J. Dehmeshki, X. Ye, X. Y. Lin, M. Valdivieso, and H. Amin, “Automated detection of lung nodules in ct images using shape-based genetic algorithm,” in *Computerized Medical Imaging and Graphics*, 2007, pp. 408–417.
- [8] M. R. Daliri and V. Torre, “Shape recognition based on kernel-edit distance,” in *Computer Vision and Image Understanding*, 2010, pp. 1097–1103.
- [9] —, “Robust symbolic representation for shape recognition and retrieval,” in *Pattern Recognition*, 2008, pp. 1782–1798.
- [10] J. Xie, P. Heng, and M. Shah, “Shape matching and modeling using skeletal context,” in *Pattern Recognition*, 2007, pp. 1756–1767.
- [11] W. Goh, “Strategies for shape matching using skeletons,” in *Computer Vision and Image Understanding*, 2007, pp. 326–345.
- [12] I. Bar-Yosef, A. Mokeichev, K. Kedem, I. Dinstein, and U. Ehrlich, “Adaptive shape prior for recognition and variational segmentation of degraded historical characters,” in *Pattern Recognition*, 2009, pp. 3348–3354.
- [13] L. Gorelick, M. Galun, E. Sharon, R. Basri, and A. Brandt, “Shape representation and classification using the poisson equation,” in *IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE*, 2006.