

Desenvolvimento de um sistema para o reconhecimento automático de plantas em Smartphone

Pedro F. Silva

Mestrado em Engenharia Matemática
Departamento de Matemática
Faculdade de Ciências da Universidade do Porto

25 Janeiro 2013

Orientação: Prof. André R. S. Marçal

Artigos em análise



James S. Cope, David P. A. Corney, Jonathan Y. Clark, Paolo Remagnino, and Paul Wilkin.

Plant species identification using digital morphometrics: A review.

Expert Syst. Appl., 39(8):7562–7573, 2012.



Eric J. Pauwels, Paul M. de Zeeuw, and Elena B. Rangelova.

Computer-assisted tree taxonomy by automated image recognition.

Eng. Appl. Artif. Intell., 22(1):26–31, February 2009.

Motivação

- As plantas são uma peça reguladora fundamental dos ecossistemas terrestres e uma fonte de grande potencial económico
- Cada vez há uma maior necessidade de recolher informações acerca dos biótopos a nível mundial, o que está dependente de técnicos altamente especializados (taxonomistas)
- O desenvolvimento dos sistemas de informação, a par da banalização do custo de mercado das tecnologias móveis e dos dispositivos de processamento de imagem configuram um novo nicho
- Quentin Wheeler: “digital images are to morphological knowledge what the Gutenberg Press was to the written word”

Vantagens do reconhecimento automático de plantas

- Necessidades reduzidas em termos de infraestruturas
- Custos globais singelos
- Versatilidade na utilização: os sistemas podem inclusive ser utilizados em partes remotas do mundo
- Utilização simples e isenta de mão de obra especializada
- Minimização dos efeitos subjetivos na escolha (problema presente nos primeiros estudos do início do século XX)
- Possibilidade de manutenção de bases de dados relativamente extensas e especializadas

Desafios do reconhecimento automático de plantas


- Deformações nos espécimes
- Fraca definição nos contornos
- Escolha de parâmetros adequados
- Terminologia errática
- Geometria dos objetos (detalhar)
- Contaminação (insetos, doença, danos mecânicos)
- **Um sistema automático tem por isso de contemplar medidas robustas e altamente discriminantes.**

Necessidade de medidas discriminantes

- As variâncias intergrupo e intragrupo são muito diferentes;
- Distinguir entre um grande número de grupos é intrinsecamente mais complexo do que distinguir de entre apenas alguns;
- O conjunto de medidas adequado a algumas espécies pode não ser portátil para outras (forma, cor, textura, etc.);
- Contaminação por confundimento: luz, inclinação, etc.

Estado de arte das técnicas de reconhecimento

- Descritores Elípticos de Fourier (DEF)
- Assinaturas de contorno
- Medidas lineares
- Indicadores de forma
- Aproximação poligonal e dimensão fractal
- Análise da rede venosa
- Análise da margem
- Análise de textura



Vantagens da análise morfológica

- Apesar de folhas da mesma planta poderem diferir em detalhe, usualmente é possível associar a espécies diferentes uma forma característica da sua folha
- Diferenças ao nível do bordo da folha e da estrutura venosa são mais difíceis de detetar
- O tamanho da folha não é uma propriedade tão consistente com a forma
- Facilidade de extração automática
- A estrutura de uma folha pode, grossomodo, ser preservada mesmo que esta tenha sido danificada (p.ex. envelhecimento)

Ideias para um sistema de reconhecimento automático

- ① Recolha e estruturação de uma base de dado de imagens de folhas de diferentes espécies
- ② Implementação de um esquema de segmentação automática de imagens
- ③ Seleção de um conjunto de variáveis com características favoráveis à classificação
- ④ Desenvolvimento de modelos estatísticos para classificação automática
- ⑤ Avaliação de resultados

Indicadores de forma (Pauwels et al., 2009)


- Excentricidade
- Proporção base/altura
- Elongação
- Solidez
- Convexidade estocástica
- Fator isoperimétrico
- Indentação máxima
- “Lobulosidade”

Indicadores de forma (Pauwels et al., 2009) - Notação

Seja


- I o objeto de interesse
- ∂I o seu bordo
- $D(I)$ o diâmetro do objeto
- $L(\partial I)$ o perímetro do objeto
- $A(I)$ a área do objeto
- $A(H(I))$ a área do polígono convexo associado ao objeto
- $d(\cdot)$ denota a distância euclídeana

Excentricidade



Calcule a excentricidade da elipse com momentos de segunda ordem idênticos aos de I . Este valor varia entre 0 e 1. 0 corresponde ao caso de uma circunferência.

Proporção base/altura




Considere quaisquer dois pixels $X, Y \in \partial I$. Escolha X e Y tais que $d(X, Y) = D(I)$. Encontre $Z, W \in \partial I$ que maximizem $d(Z, W)$ no conjunto de todos os pares de ∂I que definem um segmento ortogonal a $[XY]$. Seja $D^\perp = d(Z, W)$. A proporção base/altura é definida como o quociente $D(I)/D^\perp$. Valores perto de 0 indicam uma forma alongada.

Solidez




Calcule o rácio $A(I)/A(H(I))$. Este quociente pode ser entendido como uma certa medida de convexidade. Mede quão bem é que I se ajusta a uma forma convexa.

Convexidade estocástica



Esta variável estende a noção usual de convexidade em sentido topológico, utilizando amostragem aleatória para o cálculo. Pretende-se estimar a probabilidade de um segmento aleatório $[XY]$, $X, Y \in I$ estar completamente contido em I .

Fator isoperimétrico



O rácio $4\pi A(I)/L(\partial I)^2$ é calculado. O valor máximo de 1 é atingido para uma região circular. Contornos intrincados devolvem valores baixos.

Indentação máxima



Denote $C_{H(I)}$ e $L(H(I))$ o centróide e o comprimento de arco de $H(I)$. As distâncias $d(X, C_{H(I)})$ e $d(Y, C_{H(I)})$ são calculadas $\forall X \in H(I)$ e $\forall Y \in \partial I$. A função de indentação é $[d(X, C_{H(I)}) - d(Y, C_{H(I)})] / L(H(I))$, a qual é posteriormente amostrada em intervalos de um grau. A indentação máxima \mathfrak{D} é o máximo desta função.

Lobulosidade

A Transformada de Fourier da função de indentação é calculada após remoção da média. O espectro resultante é normalizado pela energia total. A lobulosidade é calculada como $F \times \mathcal{D}^2$, onde F designa a frequência mais baixa para a qual a energia acumulada excede 80%.

Base de dados




Class	Species	#	Class	Species	#	Class	Species	#
1	<i>Quercus suber</i>	12	6	<i>Crataegus monogyna</i>	8	11	<i>Acer palmaturu</i>	16
2	<i>Salix atrocinerea</i>	10	7	<i>Ilex aquifolium</i>	10	12	<i>Celtis sp.</i>	12
3	<i>Populus nigra</i>	10	8	<i>Nerium leander</i>	11	13	<i>Corylus avellana</i>	13
4	<i>Alnus sp.</i>	8	9	<i>Betula pubescens</i>	14	14	<i>Castanea sativa</i>	12
5	<i>Quercus robur</i>	12	10	<i>Tilia tomentosa</i>	13	15	<i>Populus alba</i>	10

Base de dados - ex. variabilidade intraclasse (classe 2)




Análise em Componentes Principais




	1	2	3	4	5	6	7	8
Comp.1	-0.25	-0.13	0.18	-0.43	-0.42	-0.37	0.44	0.43
Comp.2	0.48	0.58	0.59	0.02	0.00	-0.30	-0.02	-0.03

Análise em Componentes Principais



Análise em Componentes Principais




Análise Discriminante Linear


Class	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	Σ	Suc.
1	8	1											3			12	67%
2	1	7												2		10	70%
3			8						1				1			10	80%
4			1	6									1			8	75%
5					12											12	100%
6						7									1	8	87%
7		1					8					1				10	80%
8								11								11	100%
9			2	1			1		10							14	71%
10										13						13	100%
11											16					16	100%
12												10		2		12	83%
13	1												12			13	92%
14		3										1		8		12	67%
15															10	10	100%

Validação cruzada com divisão em treino (70%) e teste (30%): 13% de erro

Classificação Hierárquica



Classificação Hierárquica



Conclusões

- As medidas apresentadas parecem adequadas para o desenvolvimento de um sistema nas condições pretendidas.
- O cálculo das medidas é pouco dispendioso em comparação com outros métodos de análise.
- O comportamento das duas primeiras componentes principais configura uma situação favorável à classificação automática.
- O resultado da classificação obtido é promissor mesmo para um classificador simples.
- A classificação hierárquica fornece um resultado altamente desejável no contexto de um sistema de reconhecimento automático, dada a sua interpretabilidade natural.

Agradecimentos

- Prof. Doutor Rubim Almeida da Silva
Professor Auxiliar do Departamento de Biologia da Faculdade de Ciências da Universidade do Porto pela seleção e colheita das folhas que compõe a base de dados utilizada.