

Análise de Imagens

Aula 9: Características de Imagem

Prof. Alexandre Xavier Falcão

afalcao@ic.unicamp.br.

IC - UNICAMP

Roteiro da Aula

- Assinaturas de forma
- Funções de Distância
- Combinando descritores

Ver livro do Luciano, notas de proc. de imagens usando grafos e relatório técnico IC-05-21.

Descritor de Saliências de Segmentos

Um descritor mais simples do que as saliências de contorno, mas com maior eficácia em algumas aplicações, armazena as saliências de segmentos do contorno como características. Partindo de um ponto inicial, dividimos o contorno em K segmentos e somamos as áreas de influência dos pontos de cada segmento fora e dentro do contorno.

Descritor de Saliências de Segmentos

Segmentos convexos terão área externa maior que a interna, e o contrário é válido para segmentos côncavos. A maior área (interna ou externa) é tomada como saliência do segmento. As saliências convexas recebem sinal positivo e as côncavas sinal negativo. O descritor é portanto um vetor com K valores de saliência.

Curvaturas

Seja $s(t) = x(t) + jy(t)$, $t \in [0, 1]$, a representação complexa de um contorno. A curvatura de $s(t)$ é definida para cada ponto t por

$$k(t) = \frac{\dot{x}(t)\dot{y}(t) - \ddot{x}(t)\dot{y}(t)}{(\dot{x}^2(t) + \dot{y}^2(t))^{3/2}}$$

$$k(t) = \frac{-\text{Im}\{\dot{s}(t)\ddot{s}^*(t)\}}{|\dot{s}(t)|^3}$$

onde $\dot{s}(t)$ e $\ddot{s}(t)$ podem ser obtidas pelas respectivas transformadas de Fourier: $S^{(1)}(f) = j2\pi f S(f)$ e $S^{(2)}(f) = -(2\pi f)^2 S(f)$, onde $S(f)$ é a transformada de $s(t)$.

Curvaturas

Para evitar instabilidades no cálculo das curvaturas, podemos filtrar $s(t)$, $\dot{s}(t)$, $\ddot{s}(t)$ com um filtro Gaussiano de média zero e variância σ^2 . Isto equivale a multiplicar seus espectros pela transformada do filtro, gerando

$S_{\sigma^2}(f)$, $S_{\sigma^2}^{(1)}(f)$, $S_{\sigma^2}^{(2)}(f)$. A filtragem Gaussiana, porém, afeta a estimativa de curvatura por encolher o contorno. Para evitar este problema, multiplicamos os coeficientes $S_{\sigma^2}^{(1)}(f)$ e $S_{\sigma^2}^{(2)}(f)$ por uma constante C .

$$C = \frac{\int |S(f)|^2 df}{\int |S_{\sigma^2}(f)|^2 df}$$

Descritores de Curvatura

O cálculo de curvatura envolve, portanto, calcular a inversa de $S_{\sigma^2}^{(1)}(f)C$ e $S_{\sigma^2}^{(2)}(f)C$ e aplicar a fórmula de $k(t)$ dada. Note que podemos usar os valores de $k(t)$ como características ou podemos ainda variar σ^2 para obter vetores de curvatura em diferentes escalas (*curvegram*).

Veja mais detalhes no livro do Luciano.

Outros Descritores

Existem vários outros descritores interessantes na literatura. Alguns deles serão apresentados em seminários durante o curso: BAS (Bean Statistics Angle), BIC (Border/Interior Pixel Classification), Descritores baseados em Wavelets, e TSD (Tensor Scale Descriptor).

Características e Funções de Distância

O par, vetor de características e função de distância, descreve como os objetos se distribuem no espaço. Para assinaturas, se não usarmos um ponto de partida, os vetores de características deverão ser correlacionados antes de aplicarmos a função de distância. Alguns descritores já apresentam funções de distância que levam em conta o *matching* entre vetores de características com tamanhos diferentes (e.g., função usada pelo CSS— Curvature Scale Space) ou de mesmo tamanho (e.g., função OCS— Optimal Correspondent Subsequence— usada pelo BAS).

Características e Classificadores

Quando o vetor de características independe da função de distância, ele pode ser usado em qualquer classificador. Caso contrário, a classificação deve ser baseada em *clustering*. Alguns classificadores, porém, permitem uma transformação do espaço de características, onde um novo vetor de características é formado pelas distâncias entre o objeto e alguns outros de suporte.

Funções de Distância

Sejam \vec{u} e \vec{v} dois vetores com n características, sem necessidade de *matching*. Não existe um consenso que a função de distância entre eles deva ser uma métrica, mas as mais utilizadas são as métricas L_1 (City-Block) e L_2 (Euclideana).


$$L_1(\vec{u}, \vec{v}) = \sum_{i=1}^n |u_i - v_i|$$

$$L_2(\vec{u}, \vec{v}) = \sqrt{\sum_{i=1}^n (u_i - v_i)^2}$$

Combinando Descritores

Seja $\{D_1, D_2, \dots, D_k\}$ um conjunto de descritores tais que D_i extrai um vetor de características de cada objeto e compara pares de objetos usando uma função de distância própria. Para qualquer par de objetos, O_1 e O_2 , cada descritor D_i , $i = 1, 2, \dots, k$, mede uma distância d_i entre eles. Estas distâncias podem ser combinadas em uma única distância d usando Programação Genética (GP). O descritor D resultante desta combinação é denominado **descritor composto**. O objetivo é aumentar a separabilidade entre as classes visando uma maior taxa de acerto na classificação.

Descritor Composto




Poderíamos usar Algoritmos Genéticos (GA) no lugar de Programação Genética (GP).

Programação Genética

Assim como GA, GP é uma técnica de Inteligência Artificial para resolver problemas de otimização com base em princípios biológicos de herança e evolução. Cada solução candidata é um **indivíduo** de uma população, o qual é representado por uma **estrutura de dados** (árvore, lista, pilha) de tamanho variável, em vez de uma seqüência de números (binários/reais) como em GA. Os indivíduos de uma população inicial sofrem transformações genéticas (e.g., mutação) para diversificar e melhorar os desempenhos de populações futuras, avaliadas por uma função objetivo.

Indivíduo em GP

As distâncias d_i , $i = 1, 2, \dots, k$, por exemplo, podem ser os **nós terminais** de uma árvore binária de **funções matemáticas**.



Componentes do GP

Além dos terminais e das funções matemáticas, a **reprodução** copia os indivíduos de melhor desempenho para a próxima população; o **crossover** troca subárvores entre dois indivíduos pais gerando dois filhos para aumentar a diversidade; e a **mutação** troca uma subárvore de um indivíduo por outra aleatória. O desempenho é medido pela função objetivo (**fitness function**).

Função objetivo

Podemos avaliar a separabilidade entre as classes de diversas formas ou os acertos de um classificador. Uma sugestão é tornar a seleção do melhor indivíduo independente do classificador. Por exemplo, podemos gerar um grafo onde os nós são os objetos do conjunto de dados Z e os arcos são formados pelos $k - vizinhos$ mais próximos (ou vizinhos dentro de uma dada distância). Como sabemos as classes em Z , temos como medir o **corte normalizado** de cada indivíduo. O indivíduo que minimiza o corte é aquele que maximiza a separabilidade entre as classes.

Algoritmo

1. Gere uma população inicial aleatória (primeira geração).
2. Para cada geração de um número máximo de gerações faça.
 - (a) Calcule o corte normalizado de cada indivíduo.
 - (b) Selecione os N melhores indivíduos.
 - (c) Gere uma nova geração por reprodução, *crossover*, e mutação dos N melhores.
3. Selecione o melhor indivíduo.

Existem várias técnicas de reprodução, *crossover*, e mutação. Veja referências em TR IC-05-21.