

UTILIZAÇÃO DA ENTROPIA NO RASTREAMENTO DE OBJETOS COM FILTRO DE PARTÍCULAS

ALESSANDRO B. OLIVEIRA[†], JACOB SCHARCANSKI[†], DANTE A. C. BARONE[†]

[†]*Instituto de Informática, Universidade Federal do Rio Grande do Sul
Caixa Postal 15.064, 91.501-970, Porto Alegre, RS, Brasil*

E-mails: aboliveira@inf.ufrgs.br, jacobs@inf.ufrgs.br, barone@inf.ufrgs.br

Abstract— This paper presents a new robust particle filter method for tracking objects in color video sequences, especially in cluttered scenes with non-rigid objects. We show an algorithm that uses the entropy of a color distribution instead of the Bhattacharyya distance. The entropy is used as similarity measurement between the target region and a particles region. In this way, we can show that objective function for particle filter can be simpler than objective function used in traditional particle filter.

Keywords— Object tracking, Particle filter, Entropy.

Resumo— O filtro de partículas representa um eficiente método para o rastreamento de objetos em seqüências de vídeo coloridas, especialmente em cenas com muitos objetos não-rígidos. Nesse trabalho, nós propomos uma nova abordagem para o rastreamento de objetos utilizando filtro de partículas. Nós desenvolvemos um algoritmo que utiliza a entropia da distribuição de cores ao invés de utilizar a distância de Bhattacharyya. A entropia é utilizada como medida de similaridade entre as regiões formadas pelo alvo a ser rastreado e suas partículas correspondentes. Dessa forma, nós demonstramos que a função objetivo para o filtro de partículas pode ser mais simples, diminuindo o tempo de processamento sem perda de rastreabilidade do alvo.

Palavras-chave— Rastreamento de Objetos, Filtro de Partículas, Entropia.

1 Introdução

O rastreamento de objetos constitui um problema de grande importância na área de processamento de imagens, pois encontra inúmeras aplicações como vigilância, visão computacional, interface homem-computador, compressão de vídeos, computação gráfica entre outras aplicações (Pérez et al 2002). A abordagem de rastreamento de objetos utilizando filtro de partículas tem mostrado bons resultados, sobretudo no rastreamento de objetos não rígidos e sujeitos às oclusões parciais. Nessa abordagem uma região de interesse a ser rastreada, tem associada a si uma distribuição de cores (Nummiaro et al 2002), que posteriormente será comparada com a distribuição de cores de outras regiões (partículas) através de suas medidas de entropia, para posterior predição da posição estimada da região de interesse através do método de integração de Monte Carlo.

A medida de entropia tem sido muito utilizada no processamento de imagens, em especial na análise de texturas.

2 Filtro de Partículas

Um filtro de partículas foi desenvolvido para rastrear ou estimar de forma recursiva uma coleção de variáveis ocultas (estados), sujeitas a um processo Markoviano, baseado unicamente nas observações indiretas dessas variáveis, sendo esse processo tipicamente não-linear e possuindo ruído não-gaussiano (Silva 2006). A abordagem do filtro de partículas consiste na construção da representação da

função densidade de probabilidade a posteriori, que pode apresentar comportamento multi-modal, baseada numa amostra w representada por um conjunto de estados s e suas respectivas funções de importância π os quais são denominados partículas.

Dessa forma, podemos escrever um conjunto de partículas na forma:

$$w_t = \{(s_t^{(1)}, \pi_t^{(1)}), (s_t^{(2)}, \pi_t^{(2)}), \dots, (s_t^{(N)}, \pi_t^{(N)})\} \quad (1)$$

Para que possamos escrever a função densidade de probabilidade condicional a posteriori vamos definir como sendo s_t a variável oculta ou estado e ξ_t as observações ambas realizadas no tempo discreto $t \in N$. Vamos definir ainda a notação de S_t e Ξ_t para respectivamente o conjunto de estados ocultos e observações do tempo inicial até o tempo t , ou seja:

$$S_t \equiv \{s_1, s_2, \dots, s_t\} \text{ e } \Xi_t \equiv \{\xi_1, \xi_2, \dots, \xi_t\}$$

Estamos mais interessados na probabilidade condicional a posteriori para um determinado tempo t , portanto podemos obter $p(s_t | \Xi_t)$ através da marginalização (ou filtragem) de $p(S_t | \Xi_t)$.

$$p(s_t | \Xi_t) = \int \dots \int_{R^{n_s}} p(s_0, \dots, s_t | \Xi_t) ds_0 \dots ds_{t-1} \quad (2)$$

Ou na forma mais compacta, segundo nossa notação:

$$p(s_t | \Xi_t) = \int_{(R^{n_s})^{t-1}} p(S_t | \Xi_t) dS_{t-1} \quad (3)$$

Vamos escrever $p(s_t | \Xi_t)$ como:

$$p(s_t | \Xi_t) = \frac{p(\Xi_t | s_t)p(s_t)}{p(\Xi_t)} \quad (4)$$

$$= \frac{p(\xi_t, \Xi_{t-1} | s_t)p(s_t)}{p(\xi_t, \Xi_{t-1})} \quad (5)$$

$$= \frac{p(\xi_t | \Xi_{t-1}, s_t)p(\Xi_{t-1} | s_t)p(s_t)}{p(\xi_t | \Xi_{t-1})p(\Xi_{t-1})} \quad (6)$$

Onde:

$$p(\Xi_{t-1} | s_t)p(s_t) = p(s_t | \Xi_{t-1})p(\Xi_{t-1}) \quad (7)$$

Substituindo na equação, ficamos com:

$$p(s_t | \Xi_t) = \frac{p(\xi_t | s_t)p(s_t | \Xi_{t-1})p(\Xi_{t-1})}{p(\xi_t | \Xi_{t-1})p(\Xi_{t-1})} \quad (8)$$

E finalmente:

$$p(s_t | \Xi_t) = \frac{p(\xi_t | s_t)p(s_t | \Xi_{t-1})}{p(\xi_t | \Xi_{t-1})} \quad (9)$$

Podemos aproximar a probabilidade condicional a posteriori como sendo:

$$p(s_t | \Xi_t) \propto p(\xi_t | s_t)p(s_t | \Xi_{t-1}) \quad (10)$$

Onde o termo referente a predição temporal, ou atualização, pode ser escrito como:

$$p(s_t | \Xi_{t-1}) = \int_{R^{n_s}} p(s_t | s_{t-1})p(s_{t-1} | \Xi_{t-1})ds_{t-1} \quad (11)$$

Também conhecida como equação de Chapman-Kolmogorov (Grigoriu 2002).

3 Método de Monte Carlo

A resolução da equação (11) é inviável computacionalmente, especialmente quando estamos trabalhando num espaço de dimensões elevadas. Portanto se faz necessário a utilização de métodos aproximados para a resolução da mesma.

O método de Monte Carlo (Bishop 2006) consiste na utilização de uma amostra gerada aleatoriamente com probabilidade de observação conhecida para aproximar o valor da função de interesse através de seu valor estimado, ou seja:

$$E_{f(s)}[g(s)] = \int g(s)f(s)ds \quad (12)$$

Onde podemos definir a função $g(s_t) = s_t$, obtendo:

$$E_{p(s_t|\Xi_t)}[s_t] = \int s_t p(s_t | \Xi_t)ds_t \quad (13)$$

Vamos definir um conjunto de estados e suas respectivas probabilidades de ocorrência associadas (pesos) como um conjunto de partículas:

$$w_t = \{(s_t^{(1)}, \pi_t^{(1)}), (s_t^{(2)}, \pi_t^{(2)}), \dots, (s_t^{(N)}, \pi_t^{(N)})\} \quad (14)$$

O peso, ou probabilidade de ocorrência de um estado pode ser aproximado na forma:

$$\pi_t^{(i)} \propto p(\xi_t | s_t^{(i)}) \quad (15)$$

Sendo os pesos normalizados:

$$\tilde{\pi}_t^{(i)} = \frac{\pi_t^{(i)}}{\sum_{j=1}^N \pi_t^{(j)}} \quad i = 1, 2, \dots, N \quad (16)$$

Vamos ainda aproximar a probabilidade condicional à posteriori como sendo (Schön 2003):

$$\hat{p}_N(s_t | \Xi_t) = \sum_{i=1}^N \tilde{\pi}_t^{(i)} \delta(s_t - s_t^{(i)}) \quad (17)$$

Onde δ representa a função delta de Dirac.

Aplicando essa aproximação a equação do valor estimado (Karlsson 2002):

$$\begin{aligned} \hat{s}_{t|t} &= \int s_t \hat{p}_N(s_t | \Xi_t) ds_t \quad (18) \\ &= \int s_t \sum_{i=1}^N \tilde{\pi}_t^{(i)} \delta(s_t - s_t^{(i)}) ds_t = \sum_{i=1}^N \tilde{\pi}_t^{(i)} s_t^{(i)} \quad (19) \end{aligned}$$

As partículas são propagadas utilizando um modelo de equações diferenciais estocásticas de primeira ordem (Sato et al 2004), e representam a probabilidade de transição dos estados entre os tempos t e $t-1$, ou seja, $p(s_t | s_{t-1})$. O modelo de dinâmica pode ser escrito na como:

$$x_t = x_{t-1} + (x_{t-1} - x_{t-2}) + e_{x,t-1} \quad (20)$$

$$y_t = y_{t-1} + (y_{t-1} - y_{t-2}) + e_{y,t-1}$$

Ou na forma matricial:

$$s_t = A s_{t-1} + B e_{t-1} \quad (21)$$

Onde A é uma matriz que define a dinâmica do objeto (determinística) e e_{t-1} é termo estocástico (termo de ruído gaussiano). Em nosso experimento utilizamos equações diferenciais de primeira ordem, portanto a matriz A e B (Sato et al 2004) são definidas como:

$$A = \begin{bmatrix} 2 & 0 & -1 & 0 \\ 0 & 2 & 0 & -1 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} \quad B = \begin{bmatrix} 10 \\ 01 \\ 00 \\ 00 \end{bmatrix} \quad (22)$$

4 Modelo para a Distribuição de Cores

O filtro de partículas realiza o rastreamento de estados que são representados pela observação de

alguma característica ou padrão. Em nossa abordagem, na aplicação de filtro de partículas para rastreamento de objetos em imagens, vamos utilizar como variável observacional a construção da distribuição de cores da região associada ao estado em questão.

A escolha da distribuição de cores como observável se deve ao fato de que ele pode ser facilmente calculado, é invariante frente a transformações de translação e rotação e sofre pouca influência frente a oclusões parciais (Nummiaro et al 2002).

Podemos definir uma distribuição de cores na posição d^* de uma dada região R:

$$p_{d^*} = \{p_{d^*}^{(u)}\}_{u=1\dots m} \quad (23)$$

Onde d^* define a posição em coordenadas (x,y) na imagem, e u a m -ésima contagem da distribuição de cores.

Dessa forma, podemos escrever:

$$p_{d^*}^{(u)} = f \sum_{d_i \in R} k\left(\frac{\|d^* - d_i\|}{a}\right) \delta[h(d_i) - u] \quad (24)$$

Onde δ é a função delta de Dirac, a é uma constante de proporcionalidade, f é um fator de normalização para que $\sum_{u=1}^m p_{d^*}^{(u)} = 1$, e $h(d_i)$ é o histograma do i -ésimo elemento da região R.

A função k representa uma função importância ou kernel da distribuição, e geralmente é definida como:

$$k(r) = \begin{cases} 1 - r^2 & \rightarrow r < 0 \\ 0 & \rightarrow r \geq 0 \end{cases} \quad (25)$$

Vamos considerar em nosso trabalho a função kernel constante, e $k \equiv 1$. Dessa forma nossa distribuição de cores se torna simplesmente o histograma de cores da região que caracteriza nosso estado. Na figura abaixo temos em destaque a região a ser rastreada, definida a priori, centrada na posição $x=52$ e $y=56$ e definida pelo retângulo de 13 por 17 pixels. A imagem esta no espaço de cores RGB, e para a construção do histograma o espaço de cores foi requantizado para $8 \times 8 \times 8$ pilhas, ou seja, contagens no histograma de cores, totalizando 512 cores.



Figura 1. Região do alvo a ser rastreado.




Figura 2. Histograma referente a região do alvo, em destaque na Figura 1.

5 Utilização da Entropia

Medidas de entropia são bastante utilizadas como medidas de caracterização de texturas em matrizes de co-ocorrência. Ao contrário da abordagem tradicional do filtro de partículas, que utiliza a distância de Bhattacharyya para determinar a diferença entre duas distribuições (Pérez et al 2002). Em nosso trabalho nós calculamos a entropia das distribuições de cores através da fórmula:

$$S_{entropia} = - \sum_{i=1}^n p_i \log(p_i) \quad (26)$$

Onde p_i representa a probabilidade de ocorrência da i -ésima cor no histograma, e os pesos $\pi^{(s)}$, proporcionais ao grau de similaridade entre as regiões são obtidos através da distribuição normal:

$$\pi^{(s)} = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(S^{(n)} - S^*)^2}{2\sigma^2}} \quad (27)$$

Onde S^* representa a entropia da distribuição do alvo a ser rastreado e $S^{(n)}$ a medida de entropia para as distribuições de cores da n -ésima partícula.

Nas figuras 3 podemos observar a comparação dos pesos entre a região alvo (indicada na Figura 1) e o restante da imagem.

que representou a melhor diferenciação do alvo em relação ao restante da imagem, e conseqüentemente o melhor rastreamento.




Figura 3. Gráficos de superfície mostrando o peso calculado entre a região do alvo (figura 1) e o restante da imagem. De cima para baixo: $\sigma = 1.2$, $\sigma = 0.4$ e $\sigma = 0.1$.

6 Resultados Experimentais

Nosso algoritmo foi desenvolvido em MATLAB, utilizando duas seqüências de vídeos disponibilizadas no próprio software (ver tabela 1). Os valores de σ foram obtidos experimentalmente, e para as simulações foi utilizado o valor de $\sigma = 0.1$

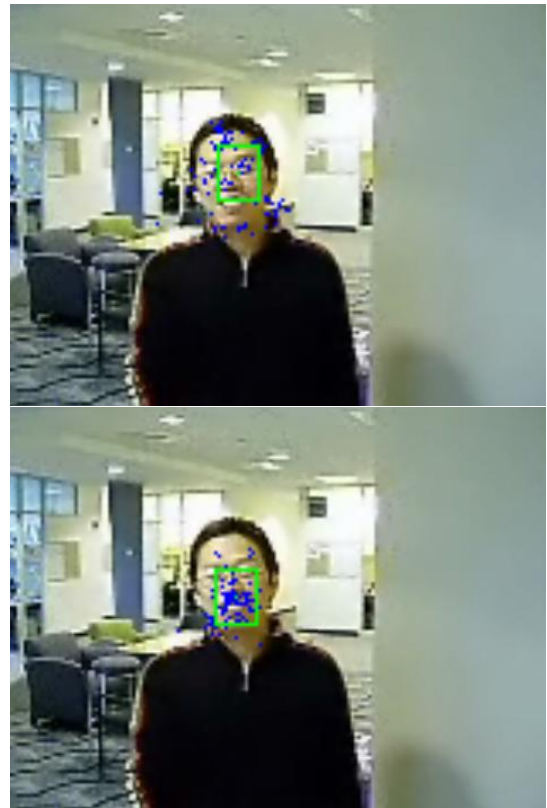



Figura 4. Comparação entre a abordagem proposta, imagem acima e a abordagem tradicional, imagem abaixo. Frame 34 da seqüência de vídeo 1.






Figura 5. Comparação entre a abordagem proposta, imagem acima e a abordagem tradicional, imagem abaixo. Frame 62 da seqüência de vídeo 1.



Figura 7. Comparação entre a abordagem proposta, imagem acima e a abordagem tradicional, imagem abaixo. Frame 5 da seqüência de vídeo 2.



Figura 6. Comparação entre a abordagem proposta, imagem acima e a abordagem tradicional, imagem abaixo. Frame 86 da seqüência de vídeo 1.



Figura 8. Comparação entre a abordagem proposta, imagem acima e a abordagem tradicional, imagem abaixo. Frame 35 da seqüência de vídeo 2.






Figura 9. Comparação entre a abordagem proposta, imagem acima e a abordagem tradicional, imagem abaixo. Frame 65 da seqüência de vídeo 2.

Podemos observar que a abordagem proposta nesse artigo foi capaz de rastrear o objeto, apesar de apresentar resultados ligeiramente diferentes daqueles obtidos com a abordagem de filtro de partículas tradicional quanto à posição do alvo estimada. No entanto, cabe ressaltar que a utilização de entropia como medida de similaridade possui um custo computacional menor do que na abordagem tradicional. Os resultados de tempo de processamento podem ser vistos na tabela 2:

Tabela 1. Informações sobre os vídeos utilizados na simulação.

Seqüência vídeo	Vídeo 1	Vídeo 2
Figuras no artigo	4,5,6	7,8,9
Número de Frames	86	210
Frames por segundo (fps)	15	30
Resolução	160x120	160x120
Espaço de cores	RGB	RGB
Bits por canal	8	8

Tabela 2. Comparação do tempo aproximado de processamento em segundos para o rastreamento utilizando filtro de partículas para as seqüências de vídeo.

Filtro de Partículas	Tempo de processamento (s)	
	Distância de Bhattacharyya	Método proposto
Vídeo 1	~ 72 s	~ 19 s
Vídeo 2	~ 65 s	~ 16 s

7 Conclusão

Através desse trabalho podemos concluir que a medida de entropia da distribuição de cores de uma região pode ser utilizada como critério de similaridade para o rastreamento de objetos utilizando filtro de partículas. Apesar dos resultados apresentarem uma pequena diferença na estimativa da posição do alvo (em relação aos resultados obtidos no filtro de partículas tradicional), o algoritmo proposto foi capaz de rastrear o objeto

utilizando um custo computacional menor do que o utilizado na abordagem tradicional de filtro de partículas.

Referências Bibliográficas

- Aherne, F. J., Thacker, N. A. and Rockett, P. I. (1997) "The Bhattacharyya Metric as an Absolute Similarity Measure for Frequency Coded Data", *Kybernetika*, vol. 32, no. 4, pp. 001-007.
- Bishop, C. M. (2006) "Pattern Recognition and Machine Learning", Springer.
- Grigoriu, M. (2002) "Stochastic Calculus: Applications in Science and Engineering", Birkhäuser.
- Karlsson, R. (2002) "Simulation Based Methods for Target Tracking", *Thesis*, Linköping Universitet, Sweden.
- MATLAB, Matlab is trademark of The MathWorks.
- Nummiaro, K., Koller-Meier, E. and Gool, L. V. (2002) "Object Tracking with an Adaptive Color-Based Particle Filter", *DAGM 2002*, LNCS 2449, pp. 353-360.
- Pérez, P., Hue, C., Vermaak, J. and Gangnet, M. (2002) "Color-Based Probabilistic Tracking", *ECCV*, LNCS 2350, pp. 661-675.
- Satoh, Y., Okatani, T. and Deguchi, K. (2004) "A Color-Based Probabilistic Tracking by Using Graphical Models", *Proc. Of 2004 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems*, Sendai, Japan.
- Schön, T. (2003) "On Computational Methods for Nonlinear Estimation", *Thesis*, Linköping Universitet, Sweden.
- Silva, P. R. A. (2006) "Filtro de Partículas Aperfeiçoado para Estimação de Postura de Robôs Móveis", *Tese*, ITA, Brasil.