

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO

ALESSANDRO BOF DE OLIVEIRA

**Filtro de Partículas Adaptativo para o
Tratamento de Oclusões no Rastreamento
de Objetos em Vídeos**

Dissertação apresentada como requisito parcial
para a obtenção do grau de
Mestre em Ciência da Computação

Prof. Dr. Dante Augusto Couto Barone
Orientador

Prof. Dr. Jacob Scharcanski
Co-orientador

Porto Alegre, maio de 2008

CIP – CATALOGAÇÃO NA PUBLICAÇÃO

Oliveira, Alessandro Bof de

Filtro de Partículas Adaptativo para o Tratamento de Oclusões no Rastreamento de Objetos em Vídeos / Alessandro Bof de Oliveira. – Porto Alegre: PPGC da UFRGS, 2008.

58 f.: il.

Dissertação (mestrado) – Universidade Federal do Rio Grande do Sul. Programa de Pós-Graduação em Computação, Porto Alegre, BR-RS, 2008. Orientador: Dante Augusto Couto Barone; Co-orientador: Jacob Scharcanski.

1. Processamento de imagens. 2. Filtro de partículas. 3. MCMC. 4. Rastreamento de objetos. 5. Oclusão total. I. Barone, Dante Augusto Couto. II. Scharcanski, Jacob. III. Título.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitor: Prof. José Carlos Ferraz Hennemann

Vice-Reitor: Prof. Pedro Cezar Dutra Fonseca

Pró-Reitora de Pós-Graduação: Prof^ª. Valquíria Linck Bassani

Diretor do Instituto de Informática: Prof. Flávio Rech Wagner

Coordenadora do PPGC: Prof^ª. Luciana Porcher Nedel

Bibliotecária-chefe do Instituto de Informática: Beatriz Regina Bastos Haro

... a *Patricia*.

AGRADECIMENTOS

- Ao Instituto de Informática e ao Programa de Pós-Graduação em Computação pelo apoio e infra-estrutura.
- Ao projeto CAVIAR da *University of Edinburgh* onde os vídeos utilizados nesse trabalho foram obtidos gratuitamente.
- Ao professor Dante Augusto Couto Barone, por sua orientação, apoio e motivação durante o desenvolvimento desse trabalho.
- Ao professor Jacob Scharcanski, por sua co-orientação e discussões acadêmicas.
- A minha família, pela compreensão e apoio.
- A Patricia, pelo seu amor, dedicação, paciência e carinho em todos os momentos.
- Ao projeto ROBOEDU financiado pelo PROMED/UNESCO e SETEC/MEC .
- Ao inventor do $C_{16}H_{21}NO_2$.
- Ao descobridor da $C_8H_{10}N_4O_2$.

SUMÁRIO

LISTA DE ABREVIATURAS E SIGLAS	7
LISTA DE SÍMBOLOS	8
LISTA DE FIGURAS	10
LISTA DE TABELAS	13
RESUMO	14
ABSTRACT	15
1 INTRODUÇÃO	16
1.1 Objetivo do Trabalho	16
1.2 Justificativa	16
1.3 Caracterização do Problema	17
2 REVISÃO BIBLIOGRÁFICA	18
2.1 Probabilidade	18
2.1.1 Teorema de Bayes	19
2.1.2 Distribuições de Probabilidade	19
2.1.3 Distribuição Normal	20
2.1.4 Distribuição Rayleigh	21
2.1.5 Relação Normal-Rayleigh	21
2.2 Processos Estocásticos	22
2.2.1 Processos estocásticos Markovianos	22
2.2.2 Monte Carlo via Cadeias de Markov	23
2.2.3 Algoritmo de Metrópolis	23
2.3 Rastreamento de Objetos em Vídeos: Estado da Arte	23
2.3.1 Rastreamento de Objetos com Filtragem Estocástica	24
2.3.2 Filtro de Kalman	25
2.3.3 Filtro de Partículas	26
2.3.4 Filtro de Partículas-Kalman	28
3 PROPOSTA DO TRABALHO	30
3.1 Filtro de Partículas adaptativo baseado em MCCM	30
3.1.1 Distribuição de Probabilidade Simétrica de Transição de Estados	31
3.1.2 Distribuição de Probabilidade Assimétrica de Transição de Estados	32
3.1.3 Distribuição de Cores	38

3.1.4	Modelo de Atualização da Distribuição de Cores do Objeto Rastreado . . .	39
3.1.5	Detectando Oclusões	40
3.2	Análise do Comportamento das Partículas Durante a Oclusão Total . . .	41
4	RESULTADOS EXPERIMENTAIS	45
4.1	Rastreamento de Objeto sem Oclusão	47
4.2	Rastreamento de Objeto com Oclusão Parcial	48
4.3	Rastreamento de Objetos com Oclusões Totais	49
4.4	Resultados Comparativos para o Tratamento de Oclusão Total	52
5	CONCLUSÕES	55
5.1	Perspectivas e Trabalhos Futuros	55
6	TRABALHOS RESULTANTES	56
	REFERÊNCIAS	57

LISTA DE ABREVIATURAS E SIGLAS

MCCM	Monte Carlo via Cadeia de Markov (Monte Carlo Markov Chain)
FP	Filtro de Partículas.
FP-MCCM-adaptativo	Filtro de Partículas baseado em Monte Carlo via Cadeia de Markov, adaptativo.
FK	Filtro de Kalman.
FKE	Filtro de Kalman Estendido.

LISTA DE SÍMBOLOS

$p(A)$	Probabilidade da variável aleatória A .
$p(A, B)$	Probabilidade conjunta de A e B .
$p(A B)$	Probabilidade condicional de A dado que B tenha ocorrido.
$X \sim p(A)$	Variável aleatória X gerada por uma distribuição de probabilidade $p(A)$.
\mathbf{s}_t	Variável aleatória que representa o estado no tempo t .
ξ_t	Variável aleatória que representa a observação no tempo t .
$\xi_{1:t}$	Conjunto de variáveis $\xi_1, \xi_2, \dots, \xi_t$.
π	Função peso ou importância.
μ	Média.
$\boldsymbol{\mu}$	Vetor média.
σ	Desvio padrão.
$\boldsymbol{\Sigma}$	Matriz de Covariância.
ρ	Correlação.
F, H	Operadores lineares na forma matricial.
$f(\cdot), h(\cdot)$	Operadores não-lineares na forma funcional.
$E(\cdot)$	Valor esperado.
$E(AB)$	Correlação entre as variáveis aleatórias A e B .
\mathbb{R}	Conjunto dos números reais.
\mathbb{N}	Conjunto dos números naturais.
\mathbb{R}^+	Conjunto dos números reais positivos incluindo o zero.
\mathbb{N}^+	Conjunto dos números naturais incluindo o zero.
$N(x \mu, \sigma)$	Distribuição de probabilidade Normal ou Gaussiana.
$R(r \sigma)$	Distribuição de probabilidade Rayleigh.
p_{RN}	Distribuição de probabilidade mista 2D Normal-Rayleigh.
\mathbf{q}	Distribuições de cores (histograma de cores).

$\delta(\cdot)$	Função Delta de Dirac.
$d_{Bhatt.}$	Distância de Bhattacharyya.
$\beta_{Bhatt.}$	Coefficiente de Bhattacharyya.
$min(\cdot)$	Função que retorna o menor argumento.
Σ	Somatório

LISTA DE FIGURAS

Figura 2.1:	Gráfico da função densidade de probabilidade Normal.	21
Figura 2.2:	Gráfico da função densidade de probabilidade Rayleigh.	21
Figura 3.1:	Distribuição normal bivariada utilizada para a geração das novas partículas.	33
Figura 3.2:	Gráfico do mapa de contorno da distribuição normal bivariada. O estado esta localizado no centro do gráfico (i.e. na posição (0,0)). . .	34
Figura 3.3:	Geração e propagação de um conjunto de partículas utilizando distribuições simétricas de probabilidade (distribuição Normal). Os pontos azuis representam as partículas no instante de tempo t e os círculos azuis representam a propagação das partículas no tempo $t + 1$	35
Figura 3.4:	Geração de um conjunto de partículas utilizando distribuição simétricas de probabilidade (distribuição Normal) e posterior propagação utilizando função assimétrica de probabilidade (distribuição Normal-Rayleigh, com aplicação da distribuição Normal no eixo y e Rayleigh no eixo x). Os pontos azuis representam as partículas no instante de tempo t e os círculos azuis representam a propagação das partículas no tempo $t + 1$	36
Figura 3.5:	Distribuição 2D Normal-Rayleigh utilizada para gerar novas partículas durante a oclusão total.	37
Figura 3.6:	Mapa de contorno da Normal-Rayleigh. O estado atual esta na posição (0, 0) do gráfico.	37
Figura 3.7:	Exemplo de região do alvo a ser rastreado. A região esta delimitada com bordas verdes.	39
Figura 3.8:	Histograma de cores da região do alvo definido na Figura 3.7	40
Figura 3.9:	Distância de Bhattacharyya entre a região do alvo (Figura 3.7) e o restante da imagem.	41
Figura 3.10:	Exemplo de detecção de oclusão total. A linha pontilhada representa o peso inicial $\pi_{E[st]}$ e a linha sólida o peso atualizado $\pi_{atualizado}^t$. Quando ambos apresentam valores menores do que o limiar $\pi_{ocluso} = 0.02$ a oclusão total é detectada.	42
Figura 3.11:	À esquerda, um exemplo de rastreamento sem oclusões no <i>frame</i> 60 de uma seqüência de vídeo utilizando nosso algoritmo FP-MCCM-adaptativo. À direita, gráfico de barras mostrando o respectivo peso das partículas. As partículas estão numeradas de 1 até 100.	43

Figura 3.12:	À esquerda, exemplo de rastreamento na presença de uma oclusão total no <i>frame</i> 80 da seqüência de vídeo utilizando o algoritmo FP-MCCM-adaptativo. À direita, o gráfico de barras mostra o peso das partículas. As partículas estão numeradas de 1 até 100.	43
Figura 3.13:	À esquerda, exemplo de rastreamento na presença de uma oclusão total no <i>frame</i> 97 da seqüência de vídeo utilizando o algoritmo FP-MCCM-adaptativo. À direita, o gráfico de barras mostra o peso das partículas. As partículas estão numeradas de 1 até 100.	44
Figura 4.1:	Resultados do rastreamento de objeto na ausência de oclusões utilizando o algoritmo FP-MCCM-adaptativo. À esquerda <i>frame</i> 4 da seqüência de vídeo, e à direita, o <i>frame</i> 14.	47
Figura 4.2:	Resultado do rastreamento de objeto na ausência de oclusões utilizando o algoritmo FP-MCCM-adaptativo. A figura mostra o <i>frame</i> 34 da seqüência de vídeo.	47
Figura 4.3:	Resultados do rastreamento de objeto na presença de oclusão parcial utilizando o algoritmo FP-MCCM-adaptativo. À esquerda <i>frame</i> 1 da seqüência de vídeo, e à direita, o rastreamento do objeto durante a oclusão parcial (<i>frame</i> 16).	48
Figura 4.4:	Resultado do rastreamento de objeto na presença de oclusão parcial utilizando o algoritmo FP-MCCM-adaptativo. A figura mostra o <i>frame</i> 28 da seqüência de vídeo, após a oclusão parcial.	48
Figura 4.5:	Resultados do rastreamento de objeto na presença de oclusão parcial e total utilizando o algoritmo FP-MCCM-adaptativo. À esquerda <i>frame</i> 10 da seqüência de vídeo, e à direita, o rastreamento do objeto durante a oclusão total (<i>frame</i> 64).	49
Figura 4.6:	Resultados do rastreamento de objeto na presença de oclusão parcial e total utilizando o algoritmo FP-MCCM-adaptativo. À esquerda <i>frame</i> 84 da seqüência de vídeo, mostrando o rastreamento do objeto durante uma oclusão parcial. À direita, o objeto continua a ser rastreado após as oclusões (<i>frame</i> 92).	49
Figura 4.7:	Resultados do rastreamento de objeto na presença de oclusão total utilizando o algoritmo FP-MCCM-adaptativo. À esquerda <i>frame</i> 32 da seqüência de vídeo, e à direita, o rastreamento do objeto momentos antes de sofrer a oclusão total (<i>frame</i> 60).	50
Figura 4.8:	Resultados do rastreamento de objeto na presença de oclusão total utilizando o algoritmo FP-MCCM-adaptativo. À esquerda <i>frame</i> 80 da seqüência de vídeo, mostrando o rastreamento do objeto durante a oclusão total. À direita, o objeto reaparece após a oclusão e continua sendo rastreado pelo algoritmo (<i>frame</i> 94).	50
Figura 4.9:	Resultados do rastreamento de objeto na presença de oclusão total utilizando o algoritmo FP-MCCM-adaptativo. À esquerda <i>frame</i> 1 da seqüência de vídeo, mostrando o objeto momentos antes da oclusão. À direita, no <i>frame</i> 12 o objeto já se encontra ocluso.	50
Figura 4.10:	Resultados do rastreamento de objeto na presença de oclusão total utilizando o algoritmo FP-MCCM-adaptativo. À esquerda <i>frame</i> 34 da seqüência de vídeo. O objeto reaparece após a oclusão. À direita no <i>frame</i> 68, o objeto continua a ser rastreado após a oclusão total. . .	51

Figura 4.11:	Resultados do rastreamento de objeto na presença de oclusão total utilizando o algoritmo FP-MCCM-adaptativo. À esquerda <i>frame</i> 12 da seqüência de vídeo, e à direita, o rastreamento do objeto momentos antes de sofrer a oclusão total (<i>frame</i> 48).	51
Figura 4.12:	Resultados do rastreamento de objeto na presença de oclusão total utilizando o algoritmo FP-MCCM-adaptativo. À esquerda <i>frame</i> 72 da seqüência de vídeo, mostrando o rastreamento do objeto durante a oclusão total. À direita, o objeto reaparece após a oclusão e continua sendo rastreado pelo algoritmo (<i>frame</i> 94).	51
Figura 4.13:	Resultado dos algoritmos de rastreamento para o <i>frame</i> 32 da seqüência de vídeo. No sentido horário: (a) acima à esquerda, Filtro de Partículas-Kalman; (b) acima à direita, <i>Mean-Shift</i> ; (c) abaixo à direita, nosso algoritmo(FP-MCCM-adaptativo); (d) abaixo à esquerda, Filtro de Partículas padrão.	52
Figura 4.14:	Resultado dos algoritmos de rastreamento para o <i>frame</i> 80 da seqüência de vídeo. No sentido horário: (a) acima à esquerda, Filtro de Partículas-Kalman; (b) acima à direita, <i>Mean-Shift</i> ; (c) abaixo à direita, nosso algoritmo(FP-MCCM-adaptativo); (d) abaixo à esquerda, Filtro de Partículas padrão.	53
Figura 4.15:	Resultado dos algoritmos de rastreamento para o <i>frame</i> 94 da seqüência de vídeo. No sentido horário: (a) acima à esquerda, Filtro de Partículas-Kalman; (b) acima à direita, <i>Mean-Shift</i> ; (c) abaixo à direita, nosso algoritmo(FP-MCCM-adaptativo); (d) abaixo à esquerda, Filtro de Partículas padrão.	54

LISTA DE TABELAS

Tabela 4.1:	Nomes dos arquivos de vídeo utilizados nos experimentos de rastreamento.	45
Tabela 4.2:	Parâmetro dos vídeos utilizados.	45
Tabela 4.3:	Parâmetros do algoritmo FP-MCCM-adaptativo.	46

RESUMO

O rastreamento de objetos em vídeos representa um importante problema na área de processamento de imagens, quer seja pelo grande número de aplicações envolvidas, ou pelo grau de complexidade que pode ser apresentado. Como exemplo de aplicações, podemos citar sua utilização em áreas como robótica móvel, interface homem-máquina, medicina, automação de processo industriais até aplicações mais tracionais como vigilância e monitoramento de trafego. O aumento na complexidade do rastreamento se deve principalmente a interação do objeto rastreado com outros elementos da cena do vídeo, especialmente nos casos de oclusões parciais ou totais. Quando uma oclusão ocorre a informação sobre a localização do objeto durante o rastreamento é perdida parcial ou totalmente. Métodos de filtragem estocástica, utilizados para o rastreamento de objetos, como os Filtros de Partículas não apresentam resultados satisfatórios na presença de oclusões totais, onde temos uma descontinuidade na trajetória do objeto. Portanto torna-se necessário o desenvolvimento de métodos específicos para tratar o problema de oclusão total. Nesse trabalho, nós desenvolvemos uma abordagem para tratar o problema de oclusão total no rastreamento de objetos utilizando Filtro de Partículas baseados em Monte Carlo via Cadeia de Markov (MCCM) com função geradora de partículas adaptativa. Durante o rastreamento do objeto, em situações onde não há oclusões, nós utilizamos uma função de probabilidade geradora simétrica. Entretanto, quando uma oclusão total, ou seja, uma descontinuidade na trajetória é detectada, a função geradora torna-se assimétrica, criando um termo de “inércia” ou “arraste” na direção do deslocamento do objeto. Ao sair da oclusão, o objeto é novamente encontrado e a função geradora volta a ser simétrica novamente.

Palavras-chave: Processamento de imagens, filtro de partículas, MCMC, rastreamento de objetos, oclusão total.

Adaptive MCMC-Particle Filter to Handle of Occlusions in Object Tracking on Videos

ABSTRACT

The object tracking on video is an important task in image processing area either for the great number of involved applications, or for the degree of complexity that can be presented. How example of application, we can cite its use from robotic area, machine-man interface, medicine, automation of industry process to vigilance and traffic control applications. The increase of complexity of tracking is occasioned principally by interaction of tracking object with other objects on video, specially when total or partial occlusions occurs. When a occlusion occur the information about the localization of tracking object is lost partially or totally. Stochastic filtering methods, like Particle Filter do not have satisfactory results in the presence of total occlusions. Total occlusion can be understood like discontinuity in the object trajectory. Therefore is necessary to develop specific method to handle the total occlusion task. In this work, we develop an approach to handle the total occlusion task using MCMC-Particle Filter with adaptive sampling probability function. When there is not occlusions we use a symmetric probability function to sample the particles. However, when there is a total occlusion, a discontinuity in the trajectory is detected, and the probability sampling function becomes asymmetric. This break of symmetry creates a “drift” or “inertial” term in object shift direction. When the tracking object becomes visible (after the occlusion) it is found again and the sampling function come back to be symmetric.

Keywords: image processing, particle filter, MCMC, object tracking, total occlusion.

1 INTRODUÇÃO

1.1 Objetivo do Trabalho

O objetivo principal desse trabalho é desenvolver um algoritmo de rastreamento de objetos, baseado no algoritmo de filtro de partículas, que seja capaz de lidar com problemas de oclusão total durante o rastreamento de objetos. O método desenvolvido procura mostrar que é possível estender o algoritmo de filtro de partículas tradicional, o qual não apresenta bons resultados de rastreamento na presença de oclusões totais, através da modificação de simetria da função de probabilidade responsável pela geração de novas partículas.

Dessa forma pretendemos contribuir para a resolução dos problemas de oclusões totais encontrados em aplicações de rastreamento de objetos como monitoramento de tráfego, segurança, robótica móvel e automação industrial.

1.2 Justificativa

Com o aumento da capacidade de processamento dos computadores e a redução de custos de equipamentos de aquisição de imagens, as aplicações em processamento de imagens vem crescendo cada vez mais. Dentre as diversas áreas do processamento de imagens, o rastreamento de objetos vem ganhando destaque tanto pela sua importância, quanto pela diversidade de aplicações como por exemplo a automação de processo industriais, a robótica móvel ou a interação homem-máquina.

O problema de rastrear um objeto pode se mostrar bastante complexo, uma vez que as variáveis envolvidas como a intensidade luminosa da cena, o ruído presente na captação da imagem, o comportamento e a própria forma do objeto a ser rastreado não podem ser controlados ou conhecidos previamente.

Sem dúvida, um dos maiores desafios enfrentados no rastreamento é o problema da oclusão total. Uma oclusão total ocorre quando o objeto rastreado encontra-se totalmente obscurecido por outro objeto da cena. Vale lembrar que o objeto causador da oclusão deve ser totalmente opaco e deve possuir dimensões maiores do que o objeto rastreado, de tal modo que toda e qualquer informação a respeito do objeto rastreado é perdida. Essa perda total de informação tem como consequência a interrupção do processo de rastreamento.

Para tratar esse problema, é necessário a utilização de algoritmos de rastreamento capazes de compensar a perda de informação ocasionada pela oclusão total. Nosso trabalho propõe uma extensão do método de rastreamento baseado em filtro de partículas, onde a perda de informações ocasionados pela oclusão total é compensada pela utilização de uma função assimétrica de geração de novas partículas com parâmetros que variam de acordo com o comportamento do objeto analisado na ausência de oclusões.

1.3 Caracterização do Problema

Esse trabalho aborda o problema de rastreamento de objetos em vídeo que apresentem uma descontinuidade em sua trajetória causadas por uma oclusão total.

Vamos definir uma oclusão como a sobreposição total ou parcial do objeto rastreado por um outro objeto totalmente opaco durante um determinado período de tempo ou por um determinado número de *frames*. Em uma oclusão parcial as dimensões do objeto causador da oclusão podem variar de tamanho em relação ao objeto rastreado. Por outro lado, em oclusões totais o objeto rastreado sempre será menor que o objeto causador da oclusão.

Durante uma oclusão total, toda a informação relativa aos *pixels* que formam o objeto rastreado é perdida, ocasionando uma descontinuidade no processo de rastreamento. Sob o ponto de vista do processamento de imagens, e no contexto do processamento de sinais, podemos considerar uma oclusão parcial como uma não-linearidade na trajetória do objeto rastreado, uma vez que esse tipo de oclusão pode mascarar uma trajetória suave ou monotônica. As oclusões totais por sua vez podem ser consideradas como uma forte não-linearidade ou descontinuidade no comportamento da trajetória.

2 REVISÃO BIBLIOGRÁFICA

2.1 Probabilidade

Segundo (FARIAS; SOARES; CÉSAR, 2003) probabilidade é a base matemática sob a qual a estatística é construída, fornecendo métodos para quantificar a incerteza existente em fenômenos aleatórios. Antes de definirmos formalmente o que é probabilidade, vamos definir alguns conceitos básicos:

- Experimento aleatório: Processo de aquisição de dados relativos a um fenômeno que apresenta variabilidade em seus resultados;
- Espaço amostral: Conjunto de todos os resultados possíveis de um experimento aleatório;
- Evento: Um evento é um subconjunto do espaço amostral, podendo ser constituído de apenas um elemento, chamado então de evento simples, até o número total de elementos do espaço amostral.

De acordo com a definição *clássica*, podemos definir a probabilidade de ocorrência de um evento de interesse A resultante de um experimento aleatório com espaço amostral definido por um conjunto E como sendo a relação entre o número de casos positivos ou favoráveis a ocorrência desse evento com o número total de casos, ou seja, com o número de casos do espaço amostral, ou seja:

$$p(A) = \frac{\text{número de casos favoráveis ao evento } A}{\text{número de casos do espaço amostral } E}. \quad (2.1)$$

Essa definição clássica de probabilidade é válida apenas para os casos em que os eventos do espaço amostral são equiprováveis. Para os outros casos é necessário utilizar uma abordagem *freqüentista* para definir a probabilidade. Segundo essa abordagem, podemos redefinir a probabilidade (Equação 2.1) como sendo:

$$p(A) = \frac{\text{número de vezes que o evento } A \text{ ocorreu}}{\text{número total de repetições do experimento}}, \quad (2.2)$$

onde o número de repetições do experimento deve ser grande. Se o número de experimentos tender ao infinito, e considerando os eventos equiprováveis, a probabilidade freqüentista tende à probabilidade clássica.

Embora as definições clássica e freqüentista sejam bastante úteis, nós podemos ainda definir a probabilidade de forma matematicamente mais formal através de 3 axiomas. Novamente vamos considerar um espaço amostral E com um evento (subconjunto) A (TRIVEDI, 1982):

- **Axioma 1:** A probabilidade de A deve ser um valor entre zero e um.

$$0 \leq p(A) \leq 1. \quad (2.3)$$

- **Axioma 2:** A probabilidade de ocorrência do espaço amostral é igual a um.

$$p(E) = 1. \quad (2.4)$$

- **Axioma 3:** Para qualquer seqüência de eventos independentes A_i e A_j , ou seja, para $A_i \cap A_j = \emptyset$ com $i \neq j$ temos:

$$p\left(\bigcup_k^{i=1} A_i\right) = \sum_k^{i=1} p(A_i). \quad (2.5)$$

Outras definições pertinentes (BISHOP, 2006) ao entendimento das seções posteriores são:

Probabilidade conjunta. Probabilidade de ocorrência simultânea de dois ou mais eventos. Considerando os eventos A e B , a probabilidade conjunta desses eventos será escrita como $p(A, B)$. Se os eventos A e B são independentes nós podemos escrever a probabilidade conjunta como $p(A, B) = p(A)p(B)$.

Probabilidade condicional. É a probabilidade de um dado evento ocorrer uma vez que um segundo evento tenha ocorrido, ou seja, $p(A|B)$ é a probabilidade de que o evento A ocorra dado que o evento B tenha ocorrido.

2.1.1 Teorema de Bayes

A probabilidade Bayesiana foi desenvolvida por Thomas Bayes (1701-1761) um clérigo, cientista e matemático inglês do século XVIII. Segundo Bayes; a probabilidade fornece uma quantificação para a incerteza da ocorrência de um evento (BISHOP, 2006). Vamos considerar um experimento realizado num espaço amostral E com a ocorrência de dois eventos dependentes A e B . Supondo que não seja possível realizar medidas de probabilidade em termos clássicos ou frequentistas do evento A (i.e. o evento possui uma frequência de ocorrência extremamente baixa, ou não é possível observá-lo diretamente) segundo a probabilidade Bayesiana, é possível definir uma probabilidade condicional entre os eventos A e B como:

$$p(A|B) = \frac{p(B|A)p(A)}{p(B)}. \quad (2.6)$$

Onde $p(A|B)$ é a probabilidade *a posteriori*, $p(B|A)$ é a probabilidade de verossimilhança e $p(A)$ e $p(B)$ são probabilidades *a priori* dos eventos A e B respectivamente. A Equação 2.6 é denominada Teorema de Bayes.

Dessa forma, o nosso conhecimento sobre o evento B diminui a incerteza na quantificação da ocorrência do evento A , uma vez que ambos possuem uma relação de dependência e estão relacionados pelo Teorema de Bayes.

2.1.2 Distribuições de Probabilidade

Até o momento, utilizamos o conceito de *evento* para exprimir os resultados de experimentos aleatórios. Entretanto esse conceito é bastante geral, podendo inclusive assumir valores não numéricos. Vamos então definir o conceito de variável aleatória para quantificar numericamente a ocorrência dos eventos.

Considerando um espaço amostral E , uma variável aleatória X é definida como uma função entre os elementos do espaço amostral e o espaço dos números reais, ou seja $X : E \rightarrow \mathbb{R}$. O mapeamento entre o espaço dos números reais e o espaço de probabilidades $p : \mathbb{R} \rightarrow [0, 1]$ é denominado de função de densidade de probabilidade que irá apresentar diferentes distribuições de acordo com o comportamento das variáveis aleatórias.

Uma distribuição de probabilidade deve respeitar as condições de normalização, e não assumir valores negativos, ou seja:

$$p(X_i = x_i) \geq 0 \quad i = 1 \dots N, \quad (2.7)$$

$$\sum_{i=1}^N p(X_i = x_i) = 1. \quad (2.8)$$

De um modo geral, por questões de simplificação da notação, utiliza-se $p(x_i)$ no lugar de $p(X_i = x_i)$. Para o caso onde as variáveis aleatórias são contínuas, o somatório é substituído pela integral e a Equação 2.8 fica:

$$\int_{-\infty}^{+\infty} p(x)dx = 1 \quad (2.9)$$

O valor esperado ou esperança matemática $E[.]$ de uma seqüência de variáveis aleatórias x_i com $i = 1, 2, \dots, N$ que possui uma função densidade de probabilidade $p(x_i)$ pode ser calculado no caso discreto como:

$$E[x] = \sum_{i=1}^N x_i p(x_i), \quad (2.10)$$

ou no caso das variáveis aleatórias serem contínuas, temos:

$$E[x] = \int_{-\infty}^{+\infty} xp(x)dx. \quad (2.11)$$

Podemos ainda generalizar a definição de valor esperado para quando a seqüência de variáveis aleatórias é determinada por uma função qualquer $f(x_i)$. Ficamos assim com as equações de valor esperado:

$$E[f(x)] = \int_{-\infty}^{+\infty} f(x)p(x)dx. \quad (2.12)$$

O raciocínio pode ser estendido de forma análoga para o caso discreto.

2.1.3 Distribuição Normal

A distribuição Normal de densidade de probabilidade possui dois graus de liberdade, e é parametrizada pelos seus valores de média μ e desvio padrão σ . Sua função de densidade de probabilidade é definida como:

$$N(x|\mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}. \quad (2.13)$$

Utilizando a Equação 2.13 com os parâmetros $\mu = 0$ e $\sigma = 1$, obtemos o gráfico para a função de densidade de probabilidade Normal:




Figura 2.1: Gráfico da função densidade de probabilidade Normal.

2.1.4 Distribuição Rayleigh

A distribuição de probabilidade de Rayleigh apresenta apenas um grau de liberdade, parametrizado por σ_r . Essa distribuição é bastante utilizada em simulação do comportamento de fluídos, medidas de acurácia no lançamento de projéteis, entre outras aplicações. Sua função de densidade de probabilidade é definida pela equação:

$$R(r|\sigma) = \frac{r}{\sigma^2} e^{-\frac{r^2}{2\sigma^2}}. \quad (2.14)$$

A Figura 2.2 mostra o gráfico da função densidade de probabilidade Rayleigh com parâmetro $\sigma_r = 1$.




Figura 2.2: Gráfico da função densidade de probabilidade Rayleigh.

2.1.5 Relação Normal-Rayleigh

As distribuições Normal e Rayleigh apresentam uma relação bastante importante e útil. Para exemplificar essa relação, vamos considerar o seguinte experimento. Temos um conjunto de bolinhas, inicialmente próximas umas das outras, onde suas componentes de

velocidades v_x e v_y seguem uma distribuição normal, não correlacionadas, ambas com média zero e com mesmo desvio padrão σ ou seja:

$$v_x \sim N(x|0, \sigma), \quad (2.15)$$

$$v_y \sim N(y|0, \sigma). \quad (2.16)$$

O módulo da velocidade das bolinhas $V(r) = \sqrt{v_x^2 + v_y^2}$ segue uma distribuição de probabilidade de Rayleigh, ou seja $V \sim R(r|\sigma)$. Esse resultado é extremamente importante para estudar a dispersão das bolinhas em função de um raio de deslocamento.

Escrevendo a relação de forma mais geral (COSTA, 2006), temos que:

$$Z^2 = X^2 + Y^2, \quad (2.17)$$

onde as variáveis aleatórias X, Y e Z seguem as distribuições:

$$X \sim N(x|\mu_x, \sigma_x), \quad (2.18)$$

$$Y \sim N(y|\mu_y, \sigma_y), \quad (2.19)$$

$$Z \sim R(r|\sigma), \quad (2.20)$$

com as condições de contorno $\mu_x = \mu_y = 0$, $\sigma_x = \sigma_y = \sigma$ e $E[XY] = 0$.

2.2 Processos Estocásticos

Inúmeros fenômenos físicos são descritos através de processos estocásticos devido a sua capacidade de simular ruídos e outras incertezas intrinsecamente presentes nas observações dos fenômenos que ocorrem na natureza. Podemos citar como exemplos, os fenômenos de difusão, comportamento microscópico da matéria e a análise de sinais eletromagnéticos.

Os processos estocásticos são definidos como um conjunto de variáveis aleatórias X_1, X_2, \dots, X_t indexadas em função do tempo, e podem ser classificados como:

Processos estocásticos discretos. Quando a variável t que representa o tempo assume apenas valores discretos, ou seja, o conjunto de variáveis aleatórias pode ser escrito como $(X_t|t \in T)$ onde $T \in \mathbb{N}^+$. Nesse caso o processo estocástico também é chamado de *cadeia*.

Processo estocástico contínuo. Quando a variável tempo t assume valores contínuos, ou ainda, quando o conjunto de variáveis aleatórias é definido como $(X(t)|t \in T)$ onde $T \in \mathbb{R}^+$.

No processamento de imagens, podemos considerar a evolução temporal de um *pixel* através de uma seqüência de *frames* como sendo um processo estocástico discreto.

2.2.1 Processos estocásticos Markovianos

Um processo estocástico é dito Markoviano, ou ainda, um processo de Markov quando para todo o valor de t onde $t = 1, 2, 3, \dots, n$, for possível escrever a probabilidade condicional de suas variáveis aleatórias como sendo:

$$p(x_{t+1}|x_t, x_{t-1}, x_{t-2}, \dots, x_{t-n-1}, t_1) = p(x_{t+1}|x_t). \quad (2.21)$$

Ou seja, em processos de Markov a probabilidade de variável X_{t+1} apresentar o valor (ou estar no estado) x_{t+1} depende condicionalmente apenas da variável X_t ter apresentado o valor (ou o estado) x_t e não de todos os seus valores ou estados passados.

2.2.2 Monte Carlo via Cadeias de Markov

O método Monte Carlo via Cadeias de Markov (MCCM) faz uso do método de Monte Carlo para estimar o valor esperado de uma variável aleatória x_t ou função de variável aleatória $f(x_t)$ através de uma amostra da distribuição da probabilidade $p(x_t)$. Esse conjunto amostral da distribuição de probabilidade é gerado iterativamente através de um processo estocástico Markoviano discreto, ou uma cadeia de Markov.

Esse método é utilizado quando a distribuição de probabilidade de $p(x_t)$ não pode ser calculada diretamente, quer seja pelo elevado custo computacional necessário para efetuar os cálculos em todo o domínio da distribuição, quer seja pela falta de conhecimento prévio de sua parametrização.

Como já vimos na seção 2.1.2 o valor esperado de uma variável $x(t)$ que segue uma distribuição de probabilidade $p(x(t))$ é definido como:

$$E[x(t)] = \int_{-\infty}^{+\infty} x(t)p(x(t))dx. \quad (2.22)$$

Entretanto quando não é possível determinar $p(x)$ diretamente, podemos estimar o valor esperado através de uma amostra da distribuição de probabilidade formada pelo conjunto discreto de variáveis aleatórias independentes $x_t^{(1)}, x_t^{(2)}, \dots, x_t^{(L)}$, e assim aproximar o valor estimado através do método de Monte Carlo como:

$$E[\hat{x}_t] = \sum_{l=1}^L x_t^{(l)} p(x_t^{(l)}). \quad (2.23)$$

No MCCM a geração do conjunto de variáveis aleatórias é realizada iterativamente através de uma cadeia de Markov, ou seja, considerando $x_t^{(l)}$ como sendo o estado atual de uma das variáveis do conjunto amostral, um novo estado $x_{t+1}^{(l)}$ será gerado utilizando uma distribuição de probabilidade proposta q tal que:

$$x_{t+1}^{(l)} \sim q(x_{t+1}^{(l)} | x_t^{(l)}). \quad (2.24)$$

2.2.3 Algoritmo de Metr6polis

O algoritmo de Metr6polis (METROPOLIS; ULAM, 1949) é uma variante do algoritmo MCCM. Ele sup6e que a distribuição de probabilidade proposta para gerar o novo conjunto amostral é simétrica, ou seja, $q(x_a | x_b) = q(x_b | x_a)$ para quaisquer valores de x_a e x_b . Além disso, considerando a Equação 2.24, o candidato a constituir o novo conjunto amostral pode ser aceito com probabilidade:

$$A(x_{t+1}^{(l)*}, x_t^{(l)}) = \min \left(1, \frac{p(x_{t+1}^{(l)*})}{p(x_t^{(l)})} \right). \quad (2.25)$$

Onde, $\min(\cdot)$ retorna o menor valor entre os dois argumentos. Dessa forma, se o estado candidato a fazer parte do conjunto amostral no tempo $t + 1$ for aceito, teremos $x_{t+1}^{(l)} = x_{t+1}^{(l)*}$, caso contrário $x_{t+1}^{(l)} = x_t^{(l)}$.

2.3 Rastreamento de Objetos em Vídeos: Estado da Arte

Podemos definir um vídeo como uma seqüência temporal de imagens ou *frames*. O rastreamento de objetos em vídeo, consiste basicamente na localização de um dado objeto

de interesse em cada um dos *frames* que compõe o mesmo. Provavelmente o método mais simples e intuitivo utilizado para rastrear objetos seja a detecção de movimento utilizando a subtração de frames consecutivos pixel a pixel. Com esse método é possível destacar regiões da imagem que apresentam movimento em comparação a regiões estáticas. A limitação desse método esta no fato de detectarmos toda e qualquer variação nos valores de pixel como os causados por ruído e variação de iluminação, e não apenas as variações devido ao movimento dos objetos. Outro limitador na aplicação desse método é a dificuldade em distinguir entre os vários objetos que podem estar em movimento ao mesmo tempo. Em situações reais, ou seja, quando temos variação de luminosidade e ruído na aquisição do vídeo, e quando não possuímos informação prévia sobre o comportamento do objeto rastreado, se faz necessário a utilização de algoritmos de rastreamento mais robustos. Nas seções seguintes vamos apresentar alguns algoritmos que representam o estado da arte no rastreamento de objetos em vídeo.

2.3.1 Rastreamento de Objetos com Filtragem Estocástica

A filtragem estocástica é um método estatístico utilizado para prever o comportamento de séries modeladas por variáveis aleatórias. Esse método vem sendo largamente utilizado na área de processamento de imagens em aplicações de rastreamento de objetos em vídeo para prever estatisticamente e em tempo real a localização do objeto rastreado.

Para modelar a trajetória do objeto rastreado, é utilizado um modelo de espaço de estados definido como:

$$\mathbf{s}_t = f_t(\mathbf{s}_{t-1}, \mathbf{w}_{t-1}), \quad (2.26)$$

$$\xi_t = h_t(\mathbf{s}_t, \mathbf{v}_t). \quad (2.27)$$

Onde $f(\cdot)$ e $h(\cdot)$ são funções (geralmente não-lineares), \mathbf{s}_t é o estado no tempo t e denota a posição do objeto em coordenadas (x, y) na imagem e ξ_t denota a observação do objeto no instante t . Ambas as equações (Equações 2.27 e 2.39 possuem um termo de ruído Gaussiano modelado pelas variáveis estocásticas \mathbf{w}_{t-1} e \mathbf{v}_t que representam a incerteza nas medidas de posição e observação respectivamente, definidas como;

$$\mathbf{w}_{t-1} \sim N(\mathbf{w}_{t-1} | \mu_w, \Sigma_w), \quad (2.28)$$

$$\mathbf{v}_t \sim N(\mathbf{v}_t | \mu_v, \Sigma_v), \quad (2.29)$$

sendo $\mu_w = 0$ e $\mu_v = 0$ e Σ_w e Σ_v são matrizes de covariância. As variáveis aleatórias \mathbf{w} e \mathbf{v} são identicamente independentes $E[\mathbf{w}, \mathbf{v}] = 0$.

As Equações 2.27 e 2.39 podem ser escritas em sua forma probabilística, como sendo:

$$\mathbf{s}_t \sim p(\mathbf{s}_t | \mathbf{s}_{t-1}, \mathbf{w}_{t-1}), \quad (2.30)$$

$$\xi_t \sim p(\xi_t | \mathbf{s}_t, \mathbf{v}_t). \quad (2.31)$$

A filtragem estocástica para o rastreamento de objetos, utiliza a posição do objeto no tempo anterior (i.e. $t - 1$) representado pelo estado \mathbf{s}_{t-1} e a observação no tempo atual ξ_t para estimar a posição do objeto no tempo t . Esse processo é realizado utilizando o Teorema de Bayes para construir a probabilidade *a posteriori* da localização do objeto iterativamente e assim calcular o valor esperado de sua posição, ou ainda, o valor esperado do seu estado no tempo $\hat{\mathbf{s}}_t$.

Vamos definir a probabilidade *a posteriori* como:

$$p(\mathbf{s}_t|\xi_{1:t}) = \frac{p(\xi_{1:t}|\mathbf{s}_t)p(\mathbf{s}_t)}{p(\xi_{1:t})}, \quad (2.32)$$

onde, depois de alguma manipulação algébrica, chegamos à equação:

$$p(\mathbf{s}_t|\xi_{1:t}) = \frac{p(\xi_t|\mathbf{s}_t)p(\mathbf{s}_t|\xi_{1:t-1})}{p(\xi_t|\xi_{1:t-1})}. \quad (2.33)$$

Como as observações são realizadas de forma independente umas das outras (i.e. dependem condicionalmente apenas do estado \mathbf{s}) e possuem probabilidade *a priori* constante, podemos simplificar a probabilidade no denominador da Equação 2.33 como sendo:

$$p(\xi_t|\xi_{1:t-1}) = p(\xi_t) = \frac{1}{Z}, \quad (2.34)$$

Dessa forma, podemos simplificar a Equação 2.33 sem perda de generalidade como:

$$p(\mathbf{s}_t|\xi_{1:t}) \propto p(\xi_t|\mathbf{s}_t)p(\mathbf{s}_t|\xi_{1:t-1}). \quad (2.35)$$

O termo $p(\xi_t|\mathbf{s}_t)$ é a probabilidade de verossimilhança, e pode ser calculada através da equação 2.31. Entretanto o termo $p(\mathbf{s}_t|\xi_{1:t-1})$ não está definido nas equações de espaço de estado, sendo necessário utilizar a propriedade de Chapman-Kolmogorov para defini-lo:

$$p(\mathbf{s}_t|\xi_{1:t-1}) = \int p(\mathbf{s}_t|\mathbf{s}_{t-1})p(\mathbf{s}_{t-1}|\xi_{1:t-1})d\mathbf{s}_{t-1}, \quad (2.36)$$

Essa equação é conhecida como *passo de predição*, pois utiliza a probabilidade *a posteriori* no tempo $t - 1$ e a probabilidade de transição de estados $p(\mathbf{s}_t|\mathbf{s}_{t-1})$ (calculada através da equação 2.31 para prever o estado no tempo t). A Equação 2.35 é chamada de *passo de atualização*, pois atualiza a informação da posição fornecida pelo passo da predição com a probabilidade de verossimilhança (i.e. observação no tempo t).

Depois de definir a probabilidade *a posteriori*, o estado que representa a localização do objeto pode ser calculado através do valor esperado:

$$E_{p(\mathbf{s}_t|\xi_{1:t})}[\mathbf{s}_t] = \int \mathbf{s}_t p(\mathbf{s}_t|\xi_{1:t}) d\mathbf{s}_t. \quad (2.37)$$

E dessa forma, podemos determinar iterativamente a trajetória do objeto rastreado. Dependendo do tipo de trajetória descrita pelo objeto, nós podemos assumir diferentes modelos de filtros estocásticos com maior ou menor grau de generalização e por consequência de complexidade.

2.3.2 Filtro de Kalman

O Filtro de Kalman (FK) é um filtro estocástico utilizado para estimar a posição de objetos que apresentam uma trajetória suave e bem comportada, descrita por um modelo de espaço de estado linear com ruído Gaussiano, onde a solução é ótima e analítica. Podemos reescrever as equação de espaço de estado como:

$$\mathbf{s}_t = \mathbf{F}\mathbf{s}_{t-1} + \mathbf{w}_{t-1}, \quad (2.38)$$

$$\xi_t = \mathbf{H}\mathbf{s}_t + \mathbf{v}_t, \quad (2.39)$$

onde F e H são operadores matriciais (de acordo com as dimensões de s) lineares e os termos w_{t-1} e v_t são ruídos Gaussianos definidos como nas Equações 2.29 e 2.29. Seguindo a abordagem probabilística, podemos escrever as probabilidade *a posteriori*, de transição de estados e de verossimilhança respectivamente como probabilidades Gaussianas:

$$p(\mathbf{s}_t|\xi_{1:t}) = N(\mathbf{s}_t|\mu_{\mathbf{s}_t}, \mathbf{P}_t), \quad (2.40)$$

$$p(\mathbf{s}_t|\mathbf{s}_{t-1}) = N(\mathbf{s}_t|\mathbf{F}\mathbf{s}_{t-1}, \Sigma_w), \quad (2.41)$$

$$p(\xi_t|\mathbf{s}_t) = N(\xi_t|\mathbf{H}\mathbf{s}_t, \Sigma_v), \quad (2.42)$$

O valor estimado do estado nesse caso pode ser calculado segundo a equação 2.37 como:

$$E_{p(\mathbf{s}_t|\xi_{1:t})}[\mathbf{s}_t] = \int \mathbf{s}_t N(\mathbf{s}_t|\mu_{\mathbf{s}_t}, \mathbf{P}_t) d\mathbf{s}_t, \quad (2.43)$$

$$E_{p(\mathbf{s}_t|\xi_{1:t})}[\mathbf{s}_t] = \mu_{\mathbf{s}_t}. \quad (2.44)$$

Os valores da média $\mu_{\mathbf{s}_t}$ e da matriz de covariância \mathbf{P}_t são calculados através das equações iterativas do Filtro de Kalman (CUEVAS; ZALDIVAR; ROJAS, 2005) (RIBEIRO, 2004):

$$\mu_{\mathbf{s}_t} = \mu_{\mathbf{s}_t}^- + \mathbf{K}_t(\xi_t - \mathbf{H}\mu_{\mathbf{s}_t}^-), \quad (2.45)$$

onde $\mu_{\mathbf{s}_t}^-$ é a estimativa de $\mu_{\mathbf{s}_t}$ e \mathbf{K}_t é a matriz denominada *ganho de Kalman* definidos como:

$$\mu_{\mathbf{s}_t}^- = \mathbf{F}\mu_{\mathbf{s}_{t-1}}, \quad (2.46)$$

$$\mathbf{K}_t = \frac{\mathbf{P}_t^- \mathbf{H}'}{\mathbf{H}\mathbf{P}_t^- \mathbf{H}' + \Sigma_v}, \quad (2.47)$$

e

$$\mathbf{P}_t = (\mathbf{I} - \mathbf{K}_t \mathbf{H}) \mathbf{P}_t^-, \quad (2.48)$$

com \mathbf{P}_t^- sendo o valor estimado da matriz de covariância definida como:

$$\mathbf{P}_t^- = \mathbf{F}\mathbf{P}_{t-1}\mathbf{F}' + \Sigma_w. \quad (2.49)$$

Nas Equações 2.47 e 2.49, as matrizes \mathbf{H}' e \mathbf{F}' representam respectivamente a transposta das matrizes \mathbf{H} e \mathbf{F} .

2.3.3 Filtro de Partículas

O Filtro de Partículas (FP) utiliza um modelo de espaço de estados mais flexível e geral quando comparado ao FK e FKE. As funções $f(\cdot)$ e $h(\cdot)$ utilizadas nas equações de estado e de observação (Equações 2.27 e 2.39 respectivamente) são em geral não-lineares e suas probabilidades de transição de estados e verossimilhança podem ser não-Gaussianas (ARULAMPALAM et al., 2002) (ISARD; BLAKE, 1998). A probabilidade *a posteriori* é representada não mais por uma Gaussiana, mas por uma distribuição discreta de probabilidade definida através de um conjunto amostral e seus respectivos pesos. Cada amostra desse conjunto é denominada *partícula* (PÉREZ et al., 2002) (BISHOP, 2006).

Para construir a probabilidade *a posteriori* a partir de uma amostra de dados e calcular seu valor esperado, vamos primeiro definir um conjunto de partículas Ω_t como sendo:

$$\Omega_t = \{(\mathbf{s}_t^{(1)}, \pi_t^{(1)}), (\mathbf{s}_t^{(2)}, \pi_t^{(2)}), \dots, (\mathbf{s}_t^{(N)}, \pi_t^{(N)})\}, \quad (2.50)$$

onde N é o número de estados (ou partículas) do conjunto amostral e $\pi_t^{(n)}$ é o peso ou importância associado ao estado $\mathbf{s}_t^{(n)}$ e definido como (PéREZ et al., 2002):

$$\pi_t^{(n)} \propto \frac{p(\xi_t | \mathbf{s}_t^{(n)}) p(\mathbf{s}_t^{(n)} | \mathbf{s}_{t-1}^{(n)})}{p_{\text{amostragem}}(\mathbf{s}_t^{(n)} | \mathbf{s}_{t-1}^{(n)}, \xi_t)}. \quad (2.51)$$

O numerador na Equação 2.51 é a estimativa da probabilidade *a posteriori* e o denominador é definido como uma função proposta de probabilidade utilizada para gerar o conjunto de partículas, denominada de *probabilidade de amostragem*, ou ainda:

$$\mathbf{s}_t^{(n)} \sim p_{\text{amostragem}}(\mathbf{s}_t^{(n)} | \mathbf{s}_{t-1}^{(n)}, \xi_t). \quad (2.52)$$

Nós podemos escolher convenientemente a probabilidade de amostragem tal que seja igual à probabilidade de transição de estados. Assim nós podemos simplificar a Equação 2.51 como:

$$\pi_t^{(n)} \propto \frac{p(\xi_t | \mathbf{s}_t^{(n)}) p(\mathbf{s}_t^{(n)} | \mathbf{s}_{t-1}^{(n)})}{p(\mathbf{s}_t^{(n)} | \mathbf{s}_{t-1}^{(n)})}, \quad (2.53)$$

$$\pi_t^{(n)} \propto p(\xi_t | \mathbf{s}_t^{(n)}), \quad (2.54)$$

e agora o peso ou importância é proporcional à probabilidade de verossimilhança (ARU-LAMPALAM et al., 2002) (NUMMIARO; KOLLER-MEIER; GOOL, 2002).

Cada n -ésimo estado na amostra é inicialmente obtido através de uma distribuição de probabilidade *a priori* e posteriormente são gerados iterativamente através da probabilidade de transição de estados ou seja, através da probabilidade de amostragem:

$$\mathbf{s}_t^{(n)} \sim \begin{cases} p(\mathbf{s}_0^{(n)} | \xi_0) & t = 0, \\ p(\mathbf{s}_t^{(n)} | \mathbf{s}_{t-1}^{(n)}) & t \neq 0, \end{cases} \quad (2.55)$$

A amostra de partículas é utilizada para estimar a probabilidade *a posteriori* através do Método de Monte Carlo. Nós podemos então reescrever a Equação 2.40 como sendo (SCHON, 2003):

$$\hat{p}(\mathbf{s}_t | \xi_{1:t}) = \sum_{n=1}^N \tilde{\pi}_t^{(n)} \delta(\mathbf{s}_t - \mathbf{s}_t^{(n)}), \quad (2.56)$$

onde $\hat{p}(\mathbf{s}_t | \xi_{1:t})$ é a probabilidade *a posteriori* estimada, e $\tilde{\pi}_t^{(n)}$ é o peso ou importância normalizados tal que:

$$\tilde{\pi}_t^{(n)} = \frac{\pi_t^{(n)}}{\sum_{j=1}^N \pi_t^{(j)}}. \quad (2.57)$$

E a probabilidade de transição de estados e de verossimilhança para o Filtro de Partículas podem ser escritas seguindo a abordagem probabilística como:

$$p(\mathbf{s}_t | \mathbf{s}_{t-1}) = N(\mathbf{s}_t | f(\mu_{\mathbf{s}_{t-1}}, \Sigma_{\mathbf{w}}), \quad (2.58)$$

$$p(\xi_t | \mathbf{s}_t) = N(\xi_t | h(\mu_{\mathbf{s}_t}, \Sigma_{\mathbf{v}}). \quad (2.59)$$

Para estimar a posição do objeto, através do valor esperado do estado s , nós temos que substituir a Equação 2.56 na Equação 2.37 ficando com:

$$E_{\hat{p}(\mathbf{s}_t | \xi_{1:t})}[\mathbf{s}_t] = \int \mathbf{s}_t \sum_{n=1}^N \tilde{\pi}_t^{(n)} \delta(\mathbf{s}_t - \mathbf{s}_t^{(n)}) d\mathbf{s}_t, \quad (2.60)$$

e realizando a integração:

$$E_{\hat{p}(\mathbf{s}_t | \xi_{1:t})}[\mathbf{s}_t] = \sum_{n=1}^N \tilde{\pi}_t^{(n)} \mathbf{s}_t^{(n)}, \quad (2.61)$$

obtendo assim o valor esperado para o estado do objeto rastreado. O Filtro de Partículas pode rastrear objetos que apresentem diversos tipos de trajetórias não suaves incluindo oclusões parciais. Dentro do contexto do processamento de imagens, as oclusões parciais podem ser entendidas como não-linearidades, uma vez que a trajetória do objeto é alterada e parte das suas informações sobre o objeto são alteradas abruptamente.

Entretanto, o Filtro de Partículas não pode rastrear trajetórias que possuam descontinuidades, como ocorre na presença de oclusões totais. Quando uma oclusão total ocorre, toda informação sobre o objeto é perdida, ocasionando uma ruptura no processo de rastreamento iterativo utilizado pelos filtros estocásticos. Em tais casos é necessário utilizar outra abordagem, capaz de generalizar ainda mais o Filtro de Partículas.

2.3.4 Filtro de Partículas-Kalman

O algoritmo de rastreamento baseado no Filtro de Partículas-Kalman (SATO; OKA-TANI; DEGUCHI, 2004) utiliza um método híbrido entre o Filtro de Kalman (Seção 2.3.2) e Filtro de Partículas (Seção 2.3.3). Ao contrário do Filtro de Kalman que utiliza apenas um estado atualizado \mathbf{s}_t e um estado aproximado \mathbf{s}_t^- para inferir a posição do objeto, o filtro de Partículas-Kalman utiliza um conjunto de estados atualizados e aproximados para inferir a posição do objeto através de um método de Monte Carlo (assim como ocorre no Filtro de Partículas). O conjunto de partículas Ω_t , definido na Equação 2.50 para o Filtro de Partículas tradicional, agora é redefinido como:

$$\Omega_t = \{(\mathbf{s}_t^{(1)}, \pi_t^{(1)}, \mathbf{P}_t^{(1)}), (\mathbf{s}_t^{(2)}, \pi_t^{(2)}, \mathbf{P}_t^{(2)}), \dots, (\mathbf{s}_t^{(N)}, \pi_t^{(N)}, \mathbf{P}_t^{(N)})\}, \quad (2.62)$$

onde o termo adicional $\mathbf{P}_t^{(n)}$ representa a matriz de covariância da n -ésima partícula, associada a seu estado $\mathbf{s}_t^{(n)}$ e peso $\pi_t^{(n)}$.

De forma análoga podemos definir outro conjunto de partículas Ω_t^- denominado de conjunto de partículas aproximadas, escrito como:

$$\Omega_t^- = \{(\mathbf{s}_t^{(1)-}, \pi_t^{(1)-}, \mathbf{P}_t^{(1)-}), (\mathbf{s}_t^{(2)-}, \pi_t^{(2)-}, \mathbf{P}_t^{(2)-}), \dots, (\mathbf{s}_t^{(N)-}, \pi_t^{(N)-}, \mathbf{P}_t^{(N)-})\}, \quad (2.63)$$

onde $\mathbf{s}_t^{(n)-}$, $\pi_t^{(n)-}$ e $\mathbf{P}_t^{(n)-}$ representam os valores aproximados de estado, peso e matriz de covariância respectivamente.

O filtro de Partículas-Kalman utiliza as mesmas equações de estado (Equação 2.38) e observação (Equação 2.39) do Filtro de Kalman para descrever a dinâmica no espaço de

estados e a solução para esse sistema de equações também segue o mesmo método, onde as equações iterativas para a resolução do Filtro de Kalman (ver seção 2.3.2) são aplicadas em cada partícula para propagar e atualizar os valores dos estados. No entanto, assim como no Filtro de Partículas, a posição do objeto rastreado é obtida através do cálculo do valor esperado dos estados utilizando o Método de Monte Carlo (Equação 2.61), ou seja:

$$E[\mathbf{s}_t] = \sum_{n=1}^N \tilde{\pi}_t^{(n)} \mathbf{s}_t^{(n)}, \quad (2.64)$$

e no caso do Filtro de Partículas-Kalman, a observação referente a posição do objeto no estado \mathbf{s}_t é obtida através da equação:

$$\xi_t \equiv E[\mathbf{H}\mathbf{s}_t^-] = \sum_{n=1}^N \tilde{\pi}_t^{(n)-} \mathbf{P}_t^{(n)-} \mathbf{s}_t^{(n)-}, \quad (2.65)$$

3 PROPOSTA DO TRABALHO

3.1 Filtro de Partículas adaptativo baseado em MCCM

Nós propomos uma nova abordagem para o tratamento de oclusões totais, ou seja para o rastreamento de objetos que apresentam trajetórias com descontinuidades, utilizando Filtro de Partículas baseado em MCCM com probabilidade de transição de estados adaptativa (FP-MCCM-Adaptativo). Quando o objeto rastreado apresenta uma trajetória contínua, ou seja, sem oclusões totais, nosso filtro de partículas utiliza um modelo de espaço de estados definido como:

$$\mathbf{s}_t = \mathbf{s}_{t-1} + \mathbf{w}_{NNt}, \quad (3.1)$$

$$\xi_t = h_t(\mathbf{s}_t, \mathbf{v}_t), \quad (3.2)$$

onde a Equação de estados (Equação 3.2) não apresenta um operador sobre o estado \mathbf{s}_{t-1} , sendo a sua dinâmica descrita apenas pelo termo estocástico \mathbf{w}_{NNt-1} . A Equação de observação do modelo (Equação 3.2) é idêntica a utilizada no filtro de partículas (Seção 2.3.3). Os termos estocásticos \mathbf{w}_{NNt-1} e \mathbf{v}_{t-1} são definidos como:

$$\mathbf{w}_{NNt} \sim N(\mathbf{w}_{NNt} | \mu_w = 0, \Sigma_w), \quad (3.3)$$

$$\mathbf{v}_t \sim N(\mathbf{v}_t | \mu_v = 0, \Sigma_v). \quad (3.4)$$

Em \mathbf{w}_{NNt} a notação NN indica que essa variável aleatória é gerada através de uma distribuição Normal bidimensional com correlação $\rho = 0$.

Seguindo a abordagem probabilística, podemos escrever para nosso Filtro de Partículas baseado em MCCM com probabilidade de transição de estados simétrica, as probabilidades *a posteriori*, de transição de estados e de verossimilhança como:

$$\hat{p}(\mathbf{s}_t | \xi_{1:t}) = \sum_{n=1}^N \tilde{\pi}_t^{(n)} \delta(\mathbf{s}_t - \mathbf{s}_t^{(n)}), \quad (3.5)$$

$$p(\mathbf{s}_t | \mathbf{s}_{t-1}) = N(\mathbf{s}_t | \mu_{\mathbf{s}_{t-1}}, \Sigma_w), \quad (3.6)$$

$$p(\xi_t | \mathbf{s}_t) = N(\xi_t | h(\mathbf{s}_t), \Sigma_v). \quad (3.7)$$

Nesse caso, a probabilidade de transição de estados é Gaussiana e portanto simétrica (Equação 3.6). Quando uma oclusão é detectada, o algoritmo muda a probabilidade de transição de estados para uma distribuição assimétrica, baseada numa mistura de uma distribuição Normal e uma distribuição Rayleigh não correlacionadas. Podemos escrever

o modelo de espaço de estado para o FP-MCCM-Adaptativo com transição de estados assimétrica como:

$$\mathbf{s}_t = \mathbf{s}_{t-1} + \mathbf{w}_{NRt}, \quad (3.8)$$

$$\xi_t = h_t(\mathbf{s}_t, \mathbf{v}_t), \quad (3.9)$$

onde agora temos o termo estocástico dado por uma distribuição de probabilidade assimétrica na equação de estado (Equação 3.9). A equação de observação (Equação 3.9) permanece inalterada. Os termos estocásticos são agora definidos como:

$$\mathbf{w}_{NRt} \sim P_{NR}(\mathbf{w}_{NRt} | \mu_w = 0, \Sigma_w), \quad (3.10)$$

$$\mathbf{v}_t \sim N(\mathbf{v}_t | \mu_v = 0, \Sigma_v), \quad (3.11)$$

e podemos escrever a probabilidade de transição de estados como:

$$p(\mathbf{s}_t | \mathbf{s}_{t-1}) = P_{RN}(\mathbf{s}_t | \mathbf{s}_{t-1}, \Sigma_w). \quad (3.12)$$

Sendo que as demais probabilidades, isto é, as probabilidades *a posteriori* e de verossimilhança, continuam sendo definidas como no caso sem oclusão (Equações 3.5 e 3.7). Essa quebra de simetria na geração do conjunto de partículas é responsável por criar um termo “inercial” ou “de arraste” na direção da principal componente do objeto rastreado. Os detalhes do funcionamento do algoritmo serão tratados nas seções posteriores.

3.1.1 Distribuição de Probabilidade Simétrica de Transição de Estados

O Filtro de Partículas precisa de um processo estocástico para atualizar o conjunto amostral das partículas que irão representar a função densidade de probabilidade da localização do objeto rastreado (i.e. a probabilidade *a posteriori*). Equações diferenciais estocásticas tem sido utilizadas em grande parte das implementações de Filtros de Partículas (PÉREZ et al., 2002), (NUMMIARO; KOLLER-MEIER; GOOL, 2002) como geradores desse processo. Nosso algoritmo utiliza outro processo estocástico para gerar a nova amostra de partículas chamado de Método de Monte Carlo via Cadeia de Markov (MCCM). MCCM é um processo estocástico utilizado para atualizar os novos estados (estados no tempo t) $\mathbf{s}_t^{(n)}$ a partir dos estados antigos (estados no tempo $t - 1$) $\mathbf{s}_{t-1}^{(n)}$ através de uma função probabilidade de transição de estados proposta $p(\mathbf{s}_t | \mathbf{s}_{t-1}^{(n)})$ a qual pode ser representada por um elevado número de funções de probabilidade (BISHOP, 2006). Esses novos estados podem ser aceitos ou rejeitados de acordo com o Algoritmo de Metropolis (METROPOLIS; ULAM, 1949) com probabilidade:

$$A(\mathbf{s}_t^{(n)*}, \mathbf{s}_{t-1}^{(n)}) = \min \left(1, \frac{p(\mathbf{s}_t^{(n)*})}{p(\mathbf{s}_{t-1}^{(n)})} \right). \quad (3.13)$$

Onde $p(\mathbf{s}_t^{(n)*})$ e $p(\mathbf{s}_{t-1}^{(n)})$ são respectivamente as probabilidades de ocorrência de um novo estado proposto e do estado atual e $\min(\cdot)$ representa a função que irá retornar como resultado o argumento de menor valor. A probabilidade do novo estado ser aceito, isto é $\mathbf{s}_t^{(n)} = \mathbf{s}_t^{(n)*}$ é dada pela escolha de um número aleatório r entre $[0, 1]$ com distribuição uniforme e então é realizada a transição de estados se $A(\mathbf{s}_t^{(n)*}, \mathbf{s}_{t-1}^{(n)}) > r$.

Se o novo estado for aceito, nós fazemos $\mathbf{s}_t^{(n)} = \mathbf{s}_t^{(n)*}$ caso contrário $\mathbf{s}_t^{(n)} = \mathbf{s}_{t-1}^{(n)}$. O Algoritmo de Metropolis é utilizado recursivamente para cada instante de tempo t .

Para adaptar o Algoritmo de Metropolis para o contexto do Filtro de Partículas e o rastreamento de objetos em vídeo, nós reescrevemos a Equação 3.13 substituindo as probabilidades $p(\mathbf{s}_t^{(n)*})$ e $p(\mathbf{s}_{t-1}^{(n)})$ pelas probabilidades de verossimilhança referentes aos respectivos estados, ou seja, $p(\xi_t|\mathbf{s}_t^{(n)*})$ e $p(\xi_{t-1}|\mathbf{s}_{t-1}^{(n)})$. Essas probabilidades são proporcionais aos pesos ou importância das partículas (Equação 3.38). Dessa forma, podemos escrever o Algoritmo de Metropolis como:

$$A(\mathbf{s}_t^{(n)*}, \mathbf{s}_{t-1}^{(n)}) = \min \left(1, \frac{\pi_t^{(n)*}}{\pi_{t-1}^{(n)}} \right). \quad (3.14)$$

Em condições normais de rastreamento, ou seja, quando a trajetória não apresenta descontinuidades nós escolhemos como função de transição de estados, para gerar a nova amostra de partículas uma distribuição Normal (ou Gaussiana) bivariada (BISHOP, 2006). Assim nós podemos escrever as Equação de probabilidade *a posteriori*, de verossimilhança e de transição de estados como visto na seção 3.1, ou relembrando:

$$\hat{p}(\mathbf{s}_t|\xi_{1:t}) = \sum_{n=1}^N \tilde{\pi}_t^{(n)} \delta(\mathbf{s}_t - \mathbf{s}_t^{(n)}), \quad (3.15)$$

$$p(\xi_t|\mathbf{s}_t) = N(\xi_t|h(\mathbf{s}_t), \Sigma_v), \quad (3.16)$$

$$p(\mathbf{s}_t|\mathbf{s}_{t-1}) = N(\mathbf{s}_t|\mathbf{s}_{t-1}, \Sigma_w), \quad (3.17)$$

onde a transição entre os estados \mathbf{s}_t e \mathbf{s}_{t-1} será aceita com a probabilidade dada pela equação do Algoritmo de Metropolis (Equação 3.14).

Nessa situação, nós queremos explorar o espaço de estados de forma isotrópica, isto é, sem uma direção preferencial, uma vez que nós não sabemos nada sobre o comportamento da trajetória do objeto rastreado. A busca é baseada na posição atual do estado e um novo estado é gerado com uma distribuição de probabilidade Gaussiana bivariada. As Figuras 3.1 e 3.2 mostram respectivamente uma distribuição normal bivariada e seu mapa de contorno. Os parâmetros para geração dos gráficos da distribuição Normal bivariada são:

$$\mu_s = (0, 0), \quad (3.18)$$

$$\Sigma_w = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}. \quad (3.19)$$

3.1.2 Distribuição de Probabilidade Assimétrica de Transição de Estados

As oclusões totais representam um importante problema no rastreamento de objetos. Elas ocorrem quando o objeto rastreado sofre oclusão de outro objeto maior e opaco do que o alvo. Nessas situações ocorre perda de informação sobre o objeto rastreado e as abordagens convencionais de filtros estocásticos, incluindo Filtros de Partículas falham. Como não é possível realizar diretamente as observações sobre o objeto rastreado durante a oclusão total, é necessária a utilização de métodos que determinem a posição do objeto de forma indireta.




Figura 3.1: Distribuição normal bivariada utilizada para a geração das novas partículas.

Nós propomos uma nova abordagem para a resolução desse problema baseado na utilização de uma função adaptativa de probabilidade de transição de estados, ou seja, nosso algoritmo (FP-MCCM-adaptativo) altera a probabilidade de transição de estados da distribuição simétrica Normal bivariada (Equação 3.17) para a função assimétrica bi-dimensional Normal-Rayleigh para gerar o novo conjunto amostral de estados quando o objeto rastreado encontra-se sob oclusão total.

Podemos então escrever o modelo de espaço de estados para a situação de oclusão total como:

$$\mathbf{s}_t = \mathbf{s}_{t-1} + \mathbf{w}_{NR,t}, \quad (3.20)$$

$$\xi_t = h_t(\mathbf{s}_t, \mathbf{v}'_t), \quad (3.21)$$

onde a diferença para o modelo de espaço de estado para quando não há oclusão total (seção 3.1.1) é o termo estocástico $\mathbf{w}_{NR,t}$ que é gerado por uma distribuição de probabilidade formada por uma distribuição Normal e uma distribuição Rayleigh não correlacionadas.

O conceito básico do FP-MCMC-adaptativo com função de probabilidade assimétrica de transição de estados é o mesmo do algoritmo descrito na seção 3.1.1 (com transição simétrica de estados) com a diferença de que a Equação 3.14 é agora definida como:

$$A(\mathbf{s}_t^{(n)*}, \mathbf{s}_{t-1}^{(n)}) \equiv 1, \quad (3.22)$$

ou seja, o novo estado proposto $\mathbf{s}_t^{(n)*}$ é sempre aceito, isto é, $\mathbf{s}_t^{(n)} = \mathbf{s}_t^{(n)*}$.

Assim as probabilidades *a posteriori*, de verossimilhança e de transição de estados podem ser escritas para esse caso como:

$$\hat{p}(\mathbf{s}_t | \xi_{1:t}) = \sum_{n=1}^N \tilde{\pi}_t^{(n)} \delta(\mathbf{s}_t - \mathbf{s}_t^{(n)}), \quad (3.23)$$




Figura 3.2: Gráfico do mapa de contorno da distribuição normal bivariada. O estado está localizado no centro do gráfico (i.e. na posição (0,0)).

$$p(\xi_t | \mathbf{s}_t) = N(\xi_t | h(\mathbf{s}_t), \Sigma_{\mathbf{v}'}), \quad (3.24)$$

$$p(\mathbf{s}_t | \mathbf{s}_{t-1}) = P_{RN}(\mathbf{s}_t | \mathbf{s}_{t-1}, \Sigma_{\mathbf{w}}). \quad (3.25)$$

A distribuição bidimensional Normal-Rayleigh P_{RN} é definida como o produto de duas distribuições de probabilidade unidimensionais, uma distribuição Normal e outra distribuição Rayleigh não correlacionadas (isto é $\rho = 0$). A distribuição de Rayleigh será utilizada na principal direção de movimento do objeto rastreado. A seção 2.1.5 mostra as informações detalhadas sobre a distribuição bidimensional Normal-Rayleigh e porque utilizá-la.

O uso da distribuição assimétrica de transição de estados causa um termo de “inércia” ou “arraste” na direção da utilização da distribuição de Rayleigh, o qual será responsável por transpor a descontinuidade na trajetória ocasionada pela oclusão total. Nós podemos mostrar o aparecimento do termo de “arraste” através de uma análise qualitativa da propagação das partículas geradas pelas funções simétricas e assimétricas de densidade de probabilidade das transições de estados. Na Figura 3.3 temos a geração de um conjunto de partículas com distribuição Normal, representadas na figura por pontos azuis, e a posterior propagação das mesmas com distribuição de transição de estados simétrica (representadas por círculos azuis). Nesse caso o “centro de massa” das partículas permanece aproximadamente constante para nos instantes de tempo t e $t + 1$.

Na Figura 3.4 temos a geração das partículas seguindo uma distribuição Normal (pontos azuis) seguido da propagação das partículas utilizando a distribuição de transição de estados assimétrica (Normal-Rayleigh, sendo a distribuição Rayleigh no eixo x), representadas pelos círculos azuis. Podemos ver que nesse caso o “centro de massa” das partículas desloca-se na direção do eixo x , a qual está sendo aplicada a função de densidade Rayleigh.




Figura 3.3: Geração e propagação de um conjunto de partículas utilizando distribuições simétricas de probabilidade (distribuição Normal). Os pontos azuis representam as partículas no instante de tempo t e os círculos azuis representam a propagação das partículas no tempo $t + 1$.

3.1.2.1 Distribuição Bidimensional Normal-Rayleigh

Em nosso algoritmo, a velocidade das partículas são definidas por um vetor de variáveis aleatórias que seguem uma distribuição Normal bivariada (quando a trajetória não apresenta descontinuidades). Nós vamos considerar que essas variáveis aleatórias são independentes, isto é, cada variável é gerada por uma distribuição Normal independente, e possuem o mesmo desvio padrão σ e média zero $\mu = 0$. Nesse caso, nós podemos escrever a relação entre as componentes do vetor velocidade como:

$$R(r|\sigma) = \sqrt{N_x(x|0, \sigma)^2 + N_y(y|0, \sigma)^2}. \quad (3.26)$$

Onde $R(r|\sigma)$ é a distribuição de Rayleigh e $N_x(x|0, \sigma)$ e $N_y(y|0, \sigma)$ são as variáveis aleatórias com distribuição Normal, ou seja, as componentes (x, y) do vetor velocidade. Com essa relação, nós podemos saber a distribuição de probabilidade da velocidade das partículas. Portanto nós podemos utilizar essa distribuição de velocidades para gerar novas partículas onde nós esperamos encontrar nosso objeto rastreado.

Nós usamos uma função de probabilidade combinando uma distribuição de Rayleigh na componente principal da velocidade e uma distribuição Normal na outra direção. Esse arranjo é utilizado para atenuar os efeitos das pequenas alterações de direção na componente secundária da velocidade. Dessa forma, nós podemos escrever a regra para a criação da distribuição 2D Normal-Rayleigh:

- Se $v_x > v_y$ então $P_{RN}(x, y) = R_x(x|\sigma)N_y(y|0, \sigma)$;
- Se $v_x < v_y$ então $P_{RN}(x, y) = R_y(y|\sigma)N_x(x|0, \sigma)$;
- Se $v_x = v_y$ então $P_{NN}(x, y) = N_x(x|0, \sigma)N_y(y|0, \sigma)$.




Figura 3.4: Geração de um conjunto de partículas utilizando distribuição simétrica de probabilidade (distribuição Normal) e posterior propagação utilizando função assimétrica de probabilidade (distribuição Normal-Rayleigh, com aplicação da distribuição Normal no eixo y e Rayleigh no eixo x). Os pontos azuis representam as partículas no instante de tempo t e os círculos azuis representam a propagação das partículas no tempo $t + 1$.

Usando como exemplo o primeiro item acima, a função de probabilidade pode ser escrita como:

$$P_{RN}(x, y) = R(x|\sigma)N(y|0, \sigma), \quad (3.27)$$

onde nós temos para a distribuição de Rayleigh:

$$R(x|\sigma) = \frac{x}{\sigma^2} e^{-\frac{1}{2}\left(\frac{x}{\sigma}\right)^2}, \quad (3.28)$$

e para a distribuição Normal:

$$N(y|0, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}\left(\frac{y}{\sigma}\right)^2}, \quad (3.29)$$

e colocando as Equações 3.28 e 3.29 na Equação 3.27, nós temos:

$$P_{RN}(x, y) = \frac{x}{\sqrt{2\pi}\sigma^3} e^{-\frac{1}{2\sigma^2}(x^2+y^2)}. \quad (3.30)$$

O gráfico dessa função de probabilidade mista (Equação 3.30) bem como seu mapa de contorno podem ser vistos respectivamente nas Figuras 3.5 e 3.6. Os parâmetros utilizados para a geração dos gráficos foram:

- Para a distribuição Normal (eixo y):

$$\mu = 0, \quad \sigma = 1. \quad (3.31)$$

- Para a distribuição Rayleigh (eixo x):

$$\sigma = 1. \quad (3.32)$$




Figura 3.5: Distribuição 2D Normal-Rayleigh utilizada para gerar novas partículas durante a oclusão total.




Figura 3.6: Mapa de contorno da Normal-Rayleigh. O estado atual esta na posição $(0, 0)$ do gráfico.

3.1.3 Distribuição de Cores

Nas seções anteriores, nós mostramos as abordagens probabilísticas dos filtros estocásticos bem como nosso algoritmo adaptativo de Filtro de Partículas baseado em MCCM. Para rastrear os objetos em vídeos coloridos, nós temos que usar uma variável observável ξ_t e um operador $h(\cdot)$ apropriados na Equação de observação 3.2 nos modelos de espaço de estados. Nós definimos, em nosso trabalho, ξ_t como a distribuição de cores ou histograma referente ao estado \mathbf{s}_t e o operador $h(\cdot)$ como a distância de Bhattacharyya (AHERNE et al., 1997) entre as distribuições de cores do estado \mathbf{s}_t que representa a posição do objeto rastreado, e o padrão de distribuição de cores do alvo a ser rastreado (PÉREZ et al., 2002). Nessa seção nós vamos demonstrar como calcular o operador $h(\cdot)$, a distância de Bhattacharyya e explicar a sua relação com a probabilidade de verossimilhança.

A utilização de distribuição de cores como padrão a ser rastreado apresenta algumas características interessantes e convenientes ao rastreamento, como por exemplo, ser invariante frente a rotações e a escala do objeto e sua robustez frente a oclusões parciais e na descrição de objetos não-rígidos. Objetos não rígidos são aqueles objetos que alteram sua forma com o passar do tempo, e são de grande interesse em aplicações reais de rastreamento e localização. Além disso, o corpo humano, alvo de grande parte das aplicações de rastreamento é considerado um objeto não-rígido.

Nós vamos definir uma distribuição de cores como a região retangular (janela) R_W localizada na posição descrita pelo estado \mathbf{s}_t^* como:

$$\mathbf{q}_{\mathbf{s}_t^*} = \{q_{\mathbf{s}_t^*}^{(u)}\}_{u=1,2,3,\dots,m}, \quad (3.33)$$

onde \mathbf{s}_t^* é a posição (x, y) em coordenadas do imagem, e u é o *bin* da m -ésimo elemento da distribuição de cores. Nós definimos $\mathbf{q}_{\mathbf{s}_t^*}$ como:

$$q_{\mathbf{s}_t^*}^{(u)} = \gamma \sum_{\mathbf{s}_t^{(i)} \in R_W} k \left(\frac{\|\mathbf{s}_t^* - \mathbf{s}_t^{(i)}\|}{a} \right) \delta[\mathbf{g}(\mathbf{s}_t^{(i)}) - u], \quad (3.34)$$

sendo δ a função *Delta de Dirac*, a é uma constante de proporcionalidade, $\mathbf{g}(\mathbf{s}_t^{(i)})$ é o *bin* do histograma na posição $\mathbf{s}_t^{(i)}$, e γ é um fator de normalização tal que:

$$\gamma = \frac{1}{\sum_{u=1}^m q_{\mathbf{s}_t^*}^{(u)}}. \quad (3.35)$$

A função $k(\cdot)$ é o *kernel* (ou núcleo) que pode ser definido como uma função Gaussiana ou outro *kernel* como por exemplo o *kernel* de Epanechnikov. Em nosso trabalho nós vamos utilizar k como uma constante, ou seja, $k \equiv 1$. Com essa consideração, nossa distribuição de cores \mathbf{q} torna-se simplesmente um histograma de cores da região definida pela janela R_W .

O histograma de cores é calculado no espaço de cores RGB utilizando $8 \times 8 \times 8$ *bins*. Ou seja, ele é requantizado do espaço de cores original da imagem de 256 níveis de cinza por canal para 8 níveis de cinza por canal. A Figura 3.7 mostra um exemplo de uma região alvo, escolhida para ser rastreada, e a Figura 3.8 mostra o histograma de cores dessa região.

Em nosso FP-MCCM-adaptativo, o estado estimado é atualizado a cada tempo t através de novas observações 3.2. Para comparar o histograma de cores dessas observações



Figura 3.7: Exemplo de região do alvo a ser rastreado. A região está delimitada com bordas verdes.

quando o objeto rastreado está em movimento, nós utilizamos a distância de Bhattacharyya (AHERNE et al., 1997) entre as distribuições $q^{(u)}$ e $q'^{(u)}$ como medida da diferença entre os histogramas, como definido na Equação 3.34:

$$d_{Bhatt.} = \sqrt{1 - \rho[\mathbf{q}, \mathbf{q}']}, \quad (3.36)$$

e $\rho_{Bhatt.}[\mathbf{q}, \mathbf{q}']$ é o coeficiente de Bhattacharyya, que é definido como:

$$\rho_{Bhatt.}[\mathbf{q}, \mathbf{q}'] = \sum_{u=1}^m \sqrt{q^{(u)} q'^{(u)}}. \quad (3.37)$$

Para duas distribuições de cores ou histogramas idênticos, nós obtemos $\rho_{Bhatt.} = 1$ e $d_{Bhatt.} = 0$. A Figura 3.9 mostra a distância de Bhattacharyya entre a região do alvo (ver Figura 3.7) e as outras partes da imagem.

Na Equação 2.61, a função peso ou importância $\pi_t^{(n)}$ do Filtro de Partículas é definido como a Gaussiana da distância de Bhattacharyya entre dois histogramas de cores e proporcional a probabilidade de verossimilhança das observações ξ_t de um estado $\mathbf{s}_t^{(n)}$:

$$p(\xi_t | \mathbf{s}_t^{(n)}) \propto \pi_t^{(n)} = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(1 - \rho[\mathbf{q}(\mathbf{s}_t^{(n)}), \mathbf{q}'])}{2\sigma^2}}, \quad (3.38)$$

onde $\mathbf{q}(\mathbf{s}_t^{(n)})$ é o nosso histograma de cores construído para a n -ésima partícula do conjunto amostral e \mathbf{q}' é o histograma de cores da região do alvo. O desvio padrão σ é utilizado para modelar o ruído e a incerteza da observação ξ_t .

3.1.4 Modelo de Atualização da Distribuição de Cores do Objeto Rastreado

As mudanças de iluminação da cena captada pelo vídeo, a contaminação do histograma de cores do objeto rastreado devido ao histograma de cores da imagem de fundo




Figura 3.8: Histograma de cores da região do alvo definido na Figura 3.7

da cena contida na janela de extração do histograma, bem como as alterações do próprio histograma do objeto causado pela sua mudança de forma, podem causar perda de qualidade no processo de rastreamento. Para minimizar esse problema, nós utilizamos um modelo de atualização de distribuição de cores como descrito em (NUMMIARO; KOLLER-MEIER; GOOL, 2002). O peso ou importância do estado correspondente à posição do objeto rastreado $\pi_{E[s_t]}$ é calculado usando a Equação 3.38. Um *limiar* de ativação $\pi_{aprendizado}$ é definido para evitar que o algoritmo atualize o histograma do alvo com o ruído proveniente da captação da imagem, ou seja, que o algoritmo aprenda o ruído, ou para evitar mudanças bruscas na alteração do histograma do objeto rastreado. Essas mudanças bruscas podem ocorrer por exemplo na presença de oclusões parciais ou totais, e nesse caso não é interessante que o algoritmo aprenda essas alterações no histograma, uma vez que elas não correspondem ao objeto rastreado.

Quando $\pi_{E[s_t]} < \pi_{aprendizado}$ o modelo utiliza a Equação 3.38 para atualizar o histograma do alvo:

$$q_t^{(u)} = (1 - \alpha)q_{t-1}^{(u)} + \alpha q_{E[s_t]}^{(u)}, \quad (3.39)$$

onde $q_t^{(u)}$ é o u -ésimo *bin* do histograma de cores atualizado do padrão a ser rastreado, isto é, do histograma alvo, α é um parâmetro de aprendizado que deve variar entre $[0, 1]$, $q_{t-1}^{(u)}$ é o histograma do alvo no tempo $t - 1$ e $q_{E[s_t]}^{(u)}$ é o histograma referente à posição estimada do objeto rastreado. Com a variação do parâmetro α é possível controlar a taxa de aprendizado do modelo. Supondo $\alpha = 0$, o modelo não irá atualizar o histograma do alvo, e com $\alpha = 1$ o histograma do alvo não terá “memória”, utilizando sempre o histograma referente à posição do objeto rastreado no instante de tempo t .

3.1.5 Detectando Oclusões

Como descrito nas seções anteriores, nosso algoritmo de rastreamento (FP-MCMC-adaptativo) muda a função de probabilidade de transição de estados de simétrica para




Figura 3.9: Distância de Bhattacharyya entre a região do alvo (Figura 3.7) e o restante da imagem.

assimétrica quando ocorre uma oclusão total.

Essa quebra de simetria é necessária para criar o termo de “arraste” (componente “inercial”) na direção principal do movimento do objeto rastreado para que o FP-MCCM-adaptativo seja capaz de superar a descontinuidade representada pela oclusão total. Portanto é de extrema importância detectar quando ocorre uma descontinuidade na trajetória do objeto.

Para detectar esse evento (oclusão total) nós definimos o peso ou importância do histograma do alvo a ser rastreado em relação ao histograma da posição estimada do objeto como sendo $\pi_{E[s_t]}$ (assim como definido na Seção 3.1.4) e o peso referente a posição estimada do objeto entre os tempos t e $t - 1$ sendo definido como $\pi_{atualizado}^t$.

Quando uma oclusão total ocorre, ambos os pesos $\pi_{E[s_t]}$ e $\pi_{atualizado}^t$ apresentam um decréscimo de seu valor. Usando um valor peso de limiar $\pi_{ocluoso}$ nós podemos detectar quando uma oclusão total iniciou e terminou.

Assim, podemos criar a regra para detecção da ocorrência de oclusões totais:

- Se $\pi_{E[s_t]}$ e $\pi_{atualizado}^t \leq \pi_{ocluoso}$, então a oclusão total é detectada (iniciou);
- Se $\pi_{atualizado}^t > \pi_{ocluoso}$ então a oclusão total terminou.

Na Figura 3.10 nós temos um exemplo do funcionamento do algoritmo de detecção de oclusões totais ou descontinuidades. A linha sólida mostra o peso inicial $\pi_{E[s_t]}$ e a linha pontilhada mostra o peso atualizado $\pi_{atualizado}^t$. Quando uma oclusão ocorre, ambos decrescem até quase zero. Depois da oclusão o valor do peso atualizado $\pi_{atualizado}^t$ volta a aumentar. Nesse exemplo, o valor limiar de ativação foi definido como $\pi_{ocluoso} = 0.02$.




Figura 3.10: Exemplo de detecção de oclusão total. A linha pontilhada representa o peso inicial $\pi_{E[s_t]}$ e a linha sólida o peso atualizado $\pi_{atualizado}^t$. Quando ambos apresentam valores menores do que o limiar $\pi_{ocluído} = 0.02$ a oclusão total é detectada.

3.2 Análise do Comportamento das Partículas Durante a Oclusão Total

Nos Filtros de Partículas, o conjunto amostral de partículas (formado pelos estados e seus pesos) são usados para reconstruir a função densidade de probabilidade *a posteriori* a qual representa probabilisticamente a localização do objeto. Cada partícula contribui com seu peso ou importância para a estimativa da posição através do Método de Monte Carlo. Quando um objeto é rastreado em uma região sem oclusões totais, isto é, sem descontinuidades, existem poucas partículas com valores de pesos elevados. A grande parte das partículas apresenta valores baixos nos seus pesos. Esse comportamento pode ser explicado devido a forma da função de distribuição de probabilidade de localização do objeto que pode ser aproximada por uma distribuição Normal onde a dispersão das partículas também irá seguir essa distribuição.

Nós podemos ver um exemplo desse comportamento na Figura 3.11, onde nós temos o *frame* 60 do rastreamento de uma pessoa numa sequência de vídeo. O gráfico de barras (Figura 3.11 à esquerda) mostra que somente três partículas estão contribuindo significativamente com seus pesos para a estimativa da posição do objeto.

Quando uma descontinuidade na trajetória ocorre, isto é, quando uma oclusão total ocorre, as partículas perdem a informação sobre o objeto rastreado (alvo) e portanto seus pesos apresentam um valor baixo. Como todas as partículas perdem informação sobre o objeto, elas apresentam praticamente o mesmo valor. Nesses casos, nós não podemos utilizar uma função de probabilidade de transição de estados simétrica para gerar uma nova amostra de partículas, pois devido a distribuição das partículas ser aproximadamente Gaussiana e pelo fato de possuírem praticamente o mesmo peso, a estimativa da posição através do Método de Monte Carlo será praticamente a mesma para a nova e a antiga amostra de partículas. Para solucionar esse problema, nós utilizamos uma abordagem

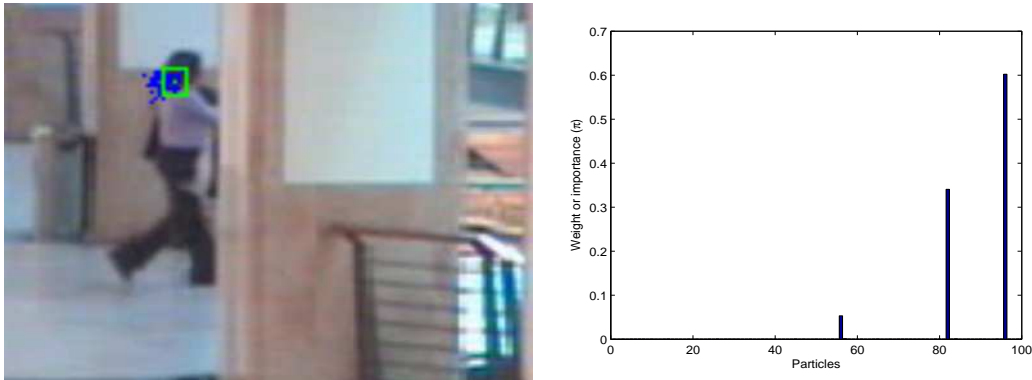


Figura 3.11: À esquerda, um exemplo de rastreamento sem oclusões no *frame* 60 de uma seqüência de vídeo utilizando nosso algoritmo FP-MCCM-adaptativo. À direita, gráfico de barras mostrando o respectivo peso das partículas. As partículas estão numeradas de 1 até 100.

assimétrica para a transição de estados para gerar uma nova amostra de partículas, criando um “arraste” ou “inércia” na principal direção de movimento do objeto. Dessa forma as partículas conseguem transpor o obstáculo e buscar o nosso alvo (objeto rastreado) sobre o objeto causador da oclusão (no exemplo um pilar). O resultado dessa amostragem realizada com a função assimétrica pode ser visto na Figura 3.12.

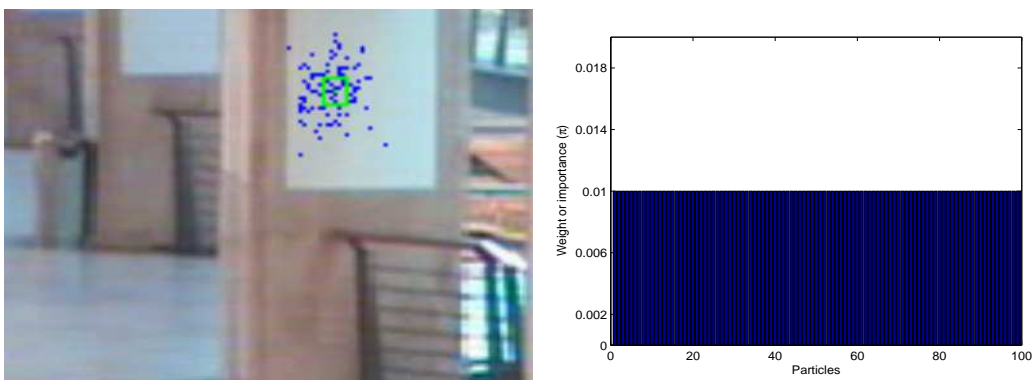


Figura 3.12: À esquerda, exemplo de rastreamento na presença de uma oclusão total no *frame* 80 da seqüência de vídeo utilizando o algoritmo FP-MCCM-adaptativo. À direita, o gráfico de barras mostra o peso das partículas. As partículas estão numeradas de 1 até 100.

Depois de transpor a oclusão total, o alvo (objeto rastreado) é encontrado novamente pelo nosso algoritmo depois do período em que esteve ocluído. A função de probabilidade de transição de estados torna-se novamente simétrica e o algoritmo de rastreamento continua seguindo a trajetória do alvo. Nós podemos ver na Figura 3.13 que os pesos das partículas tornam-se novamente não-homogêneos, ou seja, agora novamente temos o mesmo padrão visto na Figura 3.11 (à direita) de poucas partículas com grandes pesos.

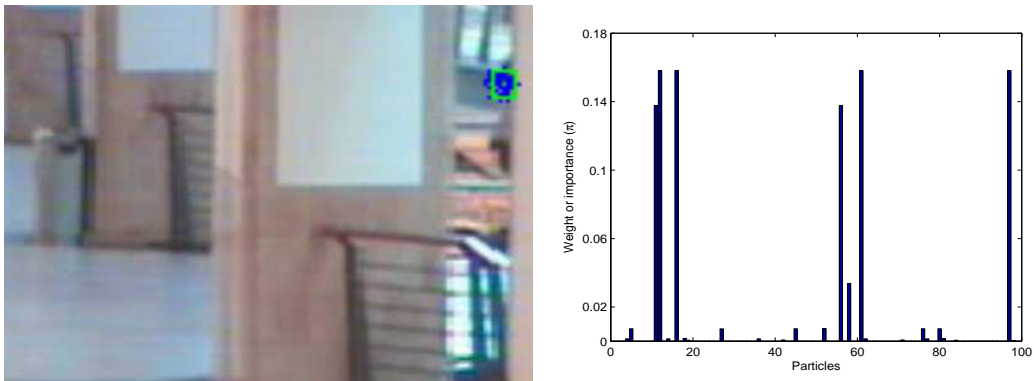


Figura 3.13: À esquerda, exemplo de rastreamento na presença de uma oclusão total no *frame* 97 da seqüência de vídeo utilizando o algoritmo FP-MCCM-adaptativo. À direita, o gráfico de barras mostra o peso das partículas. As partículas estão numeradas de 1 até 100.

4 RESULTADOS EXPERIMENTAIS

Nas próximas seções vamos apresentar alguns resultados de rastreamento de objetos obtidos com a aplicação de nosso algoritmo. Foram realizados testes em vídeos que apresentam diversos tipos de trajetória com oclusões totais, parciais e na ausência de oclusões, bem como com diferentes tipo de objetos rastreados (rígidos e não-rígidos). A Tabela 4.1 apresenta as informações básicas dos vídeos utilizados e a Tabela 4.2 mostra as características dos mesmos. A Tabela 4.3 contém os parâmetros utilizados pelo nosso algoritmo para o rastreamento dos objetos presentes nas seqüências de vídeo.

Na última seção desse capítulo, apresentamos resultados comparativos entre nosso algoritmo de rastreamento (Filtro de Partículas-MCCM-Adaptativo) e algoritmos que representam o estado da arte nessa área, como Filtro de Partículas padrão, Filtro de Partículas-Kalman e *Mean-Shift*.

Tabela 4.1: Nomes dos arquivos de vídeo utilizados nos experimentos de rastreamento. ¹MATLAB (MATLAB, 1999). ²Projeto CAVIAR (CAVIAR, 2007). ³Projeto KOGS/IAKS (KOGS/IAKS, 2007).

Nome do Vídeo	Figuras	Tipo de Oclusão	Tipo de Objeto	Origem do Vídeo
mg	4.5,4.6	total e parcial	rígido	MATLAB ¹
mcor1	4.7,4.8	total	não-rígido	Projeto CAVIAR ²
mcor2	4.1,4.2	sem oclusão	não-rígido	Projeto CAVIAR ²
hcor1	4.9,4.10	total	não-rígido	Projeto CAVIAR ²
hcor2	4.11,4.12	total	não-rígido	Projeto CAVIAR ²
van	4.3,4.4	parcial	rígido	Projeto KOGS/IAKS ³

Tabela 4.2: Parâmetros dos vídeos utilizados. ¹Resolução em *pixels* (“largura”x”altura”). ²*frames* por segundo. ³*bits* por canal.

Nome do Vídeo	Resolução ¹	<i>Frames</i>	fps ²	Sistema de Cores	bpc ³
mg	160x120	100	30	preto e branco	8
mcor1	384x288	100	25	RGB	8x8x8
mcor2	384x288	100	25	RGB	8x8x8
hcor1	384x288	120	25	RGB	8x8x8
hcor2	384x288	102	25	RGB	8x8x8
van	768x576	60	30	RGB	8x8x8

Tabela 4.3: Parâmetros do algoritmo FP-MCCM-adaptativo. ¹Limiar de ativação para detecção da oclusão. ²Limiar de ativação para o modelo de atualização do histograma de cores. ^{3,4,5}Desvios padrões para as equações de transição de estados, e observações sem e com oclusões totais respectivamente. As matrizes de covariância são formadas por: $\Sigma_w = \sigma_w^2 I$, $\Sigma_v = \sigma_v^2 I$ e $\Sigma_{v'} = \sigma_{v'}^2 I$. Onde I é a matriz identidade 2×2 .

Nome do Vídeo	Núm. Partículas	$\pi_{oclusão}$ ¹	$\pi_{aprendizado}$ ²	σ_w ³	σ_v ⁴	$\sigma_{v'}$ ⁵
mg	100	0.2	0.6	2.0	0.05	1.2
mcor1	100	0.04	0.6	2.0	0.05	1.2
mcor2	100	0.2	0.6	2.0	0.05	1.2
hcor1	100	0.2	0.6	2.0	0.05	1.2
hcor2	100	0.2	0.6	2.0	0.05	0.8
van	100	0.2	0.6	8.0	0.05	1.2

4.1 Rastreamento de Objeto sem Oclusão



Figura 4.1: Resultados do rastreamento de objeto na ausência de oclusões utilizando o algoritmo FP-MCCM-adaptativo. À esquerda *frame* 4 da seqüência de vídeo, e à direita, o *frame* 14.



Figura 4.2: Resultado do rastreamento de objeto na ausência de oclusões utilizando o algoritmo FP-MCCM-adaptativo. A figura mostra o *frame* 34 da seqüência de vídeo.

4.2 Rastreamento de Objeto com Oclusão Parcial



Figura 4.3: Resultados do rastreamento de objeto na presença de oclusão parcial utilizando o algoritmo FP-MCCM-adaptativo. À esquerda *frame 1* da seqüência de vídeo, e à direita, o rastreamento do objeto durante a oclusão parcial (*frame 16*).



Figura 4.4: Resultado do rastreamento de objeto na presença de oclusão parcial utilizando o algoritmo FP-MCCM-adaptativo. A figura mostra o *frame 28* da seqüência de vídeo, após a oclusão parcial.

4.3 Rastreamento de Objetos com Oclusões Totais




Figura 4.5: Resultados do rastreamento de objeto na presença de oclusão parcial e total utilizando o algoritmo FP-MCCM-adaptativo. À esquerda *frame* 10 da seqüência de vídeo, e à direita, o rastreamento do objeto durante a oclusão total (*frame* 64).




Figura 4.6: Resultados do rastreamento de objeto na presença de oclusão parcial e total utilizando o algoritmo FP-MCCM-adaptativo. À esquerda *frame* 84 da seqüência de vídeo, mostrando o rastreamento do objeto durante uma oclusão parcial. À direita, o objeto continua a ser rastreado após as oclusões (*frame* 92).



Figura 4.7: Resultados do rastreamento de objeto na presença de oclusão total utilizando o algoritmo FP-MCCM-adaptativo. À esquerda *frame* 32 da seqüência de vídeo, e à direita, o rastreamento do objeto momentos antes de sofrer a oclusão total (*frame* 60).



Figura 4.8: Resultados do rastreamento de objeto na presença de oclusão total utilizando o algoritmo FP-MCCM-adaptativo. À esquerda *frame* 80 da seqüência de vídeo, mostrando o rastreamento do objeto durante a oclusão total. À direita, o objeto reaparece após a oclusão e continua sendo rastreado pelo algoritmo (*frame* 94).



Figura 4.9: Resultados do rastreamento de objeto na presença de oclusão total utilizando o algoritmo FP-MCCM-adaptativo. À esquerda *frame* 1 da seqüência de vídeo, mostrando o objeto momentos antes da oclusão. À direita, no *frame* 12 o objeto já se encontra ocluído.




Figura 4.10: Resultados do rastreamento de objeto na presença de oclusão total utilizando o algoritmo FP-MCCM-adaptativo. À esquerda *frame* 34 da seqüência de vídeo. O objeto reaparece após a oclusão. À direita no *frame* 68, o objeto continua a ser rastreado após a oclusão total.



Figura 4.11: Resultados do rastreamento de objeto na presença de oclusão total utilizando o algoritmo FP-MCCM-adaptativo. À esquerda *frame* 12 da seqüência de vídeo, e à direita, o rastreamento do objeto momentos antes de sofrer a oclusão total (*frame* 48).



Figura 4.12: Resultados do rastreamento de objeto na presença de oclusão total utilizando o algoritmo FP-MCCM-adaptativo. À esquerda *frame* 72 da seqüência de vídeo, mostrando o rastreamento do objeto durante a oclusão total. À direita, o objeto reaparece após a oclusão e continua sendo rastreado pelo algoritmo (*frame* 94).

4.4 Resultados Comparativos para o Tratamento de Oclusão Total

O algoritmo FP-MCMC-adaptativo foi testado em situação de oclusão total, onde a trajetória de uma pessoa é rastreada através de um corredor de *Shopping Center* sofrendo a oclusão de uma coluna de sustentação. A seqüência de vídeo foi gerada pelo projeto CAVIAR (CAVIAR, 2007) e esta disponível na *internet* gratuitamente no *site* do projeto (ver referência). Os vídeo gerados tem resolução de 384×288 *pixels* e estão no sistema de cores RGB com $8 \times 8 \times 8$ *bits*, um total de 100 *frames* e 25 *fps* (*frames* por segundo).

Para comparar os resultados obtidos pelo nosso algoritmo, nós utilizamos três métodos diferentes de rastreamento de objetos para validar nossos resultados. Um Filtro de Partículas-Kalman descrito em (SATOHI; OKATANI; DEGUCHI, 2004), um algoritmo *Mean-Shift* de rastreamento (COMANICIU; RAMESH; MEER, 2000) e um Filtro de Partículas padrão, ou seja, que utiliza equação diferencial estocástica para gerar a amostra dos novos estados que formam o conjunto de partículas (NUMMIARO; KOLLERMEIER; GOOL, 2002) (PÉREZ et al., 2002). Em todos os algoritmos, nós utilizamos histogramas de cores como descrito na seção 3.1.3 como padrão a ser rastreado. Entretanto, nós utilizamos diferentes tamanhos de janelas para construir os histogramas. Para o Filtro de Partículas-Kalman nós utilizamos 19×25 *pixels*, para o algoritmo de rastreamento utilizando *Mean-Shift* 13×15 *pixels* e para o Filtro de Partículas padrão bem como para o nosso algoritmo desenvolvido, nós utilizamos uma janela de 7×9 *pixels*.

Na Figura 4.13 nós temos os resultados dos algoritmo de rastreamento para o *frame* 32 da seqüência de vídeo. Ela mostra a diferença entre as regiões (janelas) do alvo a ser rastreado. Nesse *frame* o objeto, isto é, a pessoa é rastreada sem a presença de oclusões (descontinuidades).



Figura 4.13: Resultado dos algoritmos de rastreamento para o *frame* 32 da seqüência de vídeo. No sentido horário: (a) acima à esquerda, Filtro de Partículas-Kalman; (b) acima à direita, *Mean-Shift*; (c) abaixo à direita, nosso algoritmo(FP-MCCM-adaptativo); (d) abaixo à esquerda, Filtro de Partículas padrão.

A Figura 4.14 mostra o *frame* 80 onde nós temos a ocorrência da oclusão total, ou seja, de uma descontinuidade. Nesse momento a informação sobre o objeto rastreado é

totalmente perdida. O Filtro de Partículas-Kalman perdeu o objeto rastreado antes do momento da oclusão (Figura 4.14a) e está rastreando uma outra pessoa da cena. O algoritmo *Mean-Shift* (Figura 4.14b) permanece na mesma posição ao encontrar um padrão de cores de fundo diferente daquele encontrado no início do rastreamento, antes mesmo de chegar a coluna causadora da oclusão, e falha em rastrear a pessoa.

O resultado do Filtro de Partículas padrão é mostrado na Figura 4.14d. Ele não consegue transpor a descontinuidade ocasionada pela oclusão total, e permanece parado quando perde as informações sobre o objeto rastreado. Vale lembrar que o Filtro de Partículas padrão possui uma probabilidade de transição de estados simétrica e por isso não consegue continuar o rastreamento da trajetória. A Figura 4.14c mostra o resultado obtido pelo nosso algoritmo (FP-MCCM-adaptativo). Nós podemos observar as partículas transpondo a coluna e seguindo na direção do comportamento do movimento do objeto ocluso.



Figura 4.14: Resultado dos algoritmos de rastreamento para o *frame* 80 da seqüência de vídeo. No sentido horário: (a) acima à esquerda, Filtro de Partículas-Kalman; (b) acima à direita, *Mean-Shift*; (c) abaixo à direita, nosso algoritmo(FP-MCCM-adaptativo); (d) abaixo à esquerda, Filtro de Partículas padrão.

Após a transposição da oclusão, quando a pessoa torna-se visível novamente (*frame* 94), nosso algoritmo é capaz de encontrar o objeto rastreado (Figure 4.15c) e continuar com o processo de rastreamento. Os outros algoritmos de rastreamento não podem seguir a trajetória da pessoa após a oclusão (Figuras 4.15a, 4.15b e 4.15c). Eles perderam totalmente a informação sobre o objeto rastreado.



Figura 4.15: Resultado dos algoritmos de rastreamento para o *frame* 94 da seqüência de vídeo. No sentido horário: (a) acima à esquerda, Filtro de Partículas-Kalman; (b) acima à direita, *Mean-Shift*; (c) abaixo à direita, nosso algoritmo(FP-MCCM-adaptativo); (d) abaixo à esquerda, Filtro de Partículas padrão.

5 CONCLUSÕES

Nosso trabalho mostrou um novo modelo de Filtros de Partículas baseados em Monte Carlo via Cadeia de Markov. Nossos resultados experimentais indicam que, potencialmente, o algoritmo proposto pode ser efetivo no tratamento de situações onde ocorrem oclusões totais (descontinuidades na trajetória). Nós assumimos que o movimento do objeto rastreado não deve variar abruptamente de direção e sentido e que as mudanças de iluminação da cena e da forma e distribuição de cores do alvo devem variar suavemente.

A principal contribuição desse trabalho é mostrar que a utilização de função de probabilidade assimétricas podem ser utilizadas em Filtros de Partículas baseados em MCCM para o tratamento de descontinuidades da trajetória ocasionados por oclusões totais. Nós podemos demonstrar que a mudança de simetria da função de probabilidade utilizada para gerar os novos estados do conjunto amostral é responsável pela habilidade do algoritmo proposto de transpor as oclusões totais.

Situações de oclusão total são muito comuns em diversas aplicações de processamento de imagens, especialmente em áreas de vigilância e monitoramento utilizando vídeo, e por isso representam um importante desafio aos métodos de rastreamento de objetos baseados em Filtro de Partículas. Nosso algoritmo proposto contribui para transpor essa limitação apresentada pelo Filtro de Partículas padrão ao evitar a interrupção do processo de rastreamento quando o objeto é temporariamente ocluído.

5.1 Perspectivas e Trabalhos Futuros

Os resultados apresentados pelo nosso algoritmo (FP-MCCM-adaptativo) em comparação com os Filtro de Partículas-Kalman, *Mean-Shift* e Filtro de Partículas padrão no tratamento de descontinuidades da trajetória de objetos rastreados são muito animadores. Com isso pretendemos aplicar nosso algoritmo em outras seqüências de vídeo com diferentes tipos de objetos a serem rastreados e outras situações de oclusão. Algumas aplicações já estão previstas, como por exemplo o rastreamento de veículos em autoestradas (monitoramento de tráfego) e aplicações de vídeo na automação de processos industriais.

Outro estudo que será realizado diz respeito à utilização de outras funções assimétricas de probabilidade para a transição de estados e um estudo mais aprofundado na área de cálculo estocástico, com o objetivo de tornar o algoritmo desenvolvido mais robusto.

O algoritmo FP-MCCM-adaptativo também será utilizado no desenvolvimento de modelos de rastreamento baseados em modelos gráficos, com o objetivo de rastrear objetos articulados em condições de oclusão. Esse trabalho será desenvolvido durante o período de doutorado, dando continuidade ao estudo e pesquisa na área de filtros estocásticos para o rastreamento de objetos em situação de oclusão iniciado durante o presente trabalho.

6 TRABALHOS RESULTANTES

- Oliveira, A. B., Scharcanski, J., Barone, D. **Utilização de Entropia no Rastreamento de Objetos com Filtro de Partículas.** In. VIII SBAI - Simpósio Brasileiro de Automação Inteligente, 2007, Florianópolis, Brasil.
- Oliveira, A. B., Scharcanski, J., Barone, D. **A New Particle Filtering Method for Tracking Moving Targets Robust to Occlusions.** Pattern Recognition Letters (a ser submetido em março de 2008).

REFERÊNCIAS

AHERNE, F. J. et al. The Bhattacharyya Metric as an Absolute Similarity Measure for Frequency Coded Data. **Kybernetika**, [S.l.], v.32, n.4, p.1–7, 1997.

ARULAMPALAM, M. S. et al. A Tutorial on Particle Filters for Online Nonlinear/Non-Gaussian Bayesian Tracking. **IEEE Transactions on Signal Processing**, [S.l.], v.50, n.02, p.174–188, 2002.

BISHOP, C. **Pattern Recognition and Machine Learning**. New York: Springer, 2006.

CAVIAR. **CAVIAR Project**: test case scenarios. Disponível em: <<http://groups.inf.ed.ac.uk/vision/CAVIAR/CAVIARDATA1>>. Acesso em: abril 2007.

COMANICIU, D.; RAMESH, V.; MEER, P. Real-Time Tracking of non-Rigid Objects using Mean Shift. In: IEEE CONFERENCE COMPUTER VISION AND PATTERN RECOGNITION, 2000, USA. **Proceedings...** [S.l.: s.n.], 2000. v.2, p.142–149.

COSTA, D. B. da. **Estatística de Ordem Superior para Canais de Desvanecimento Weibull e Nakagami-m**. 2006. Dissertação (Mestrado em Engenharia Elétrica) — UNICAMP, Campinas, SP, Brasil.

CUEVAS, E.; ZALDIVAR, D.; ROJAS, R. **Kalman Filter for Vision Tracking**. Germany: [s.n.], 2005.

FARIAS, A. A. de; SOARES, J. F.; CÉSAR, C. C. **Introdução à Estatística**. Rio de Janeiro: LTC, 2003.

ISARD, M.; BLAKE, A. CONDENSATION - Conditional Density Propagation for Visual Tracking. **Internation Journal on Computer Vision**, [S.l.], v.29, n.1, p.5–28, 1998.

KOGS/IAKS. **KOGS Project. Institut für Algorithmen und Kognitive Systeme**. Disponível em: <http://i21www.ira.uka.de/image_sequences/>. Acesso em: abril 2007.

MATLAB. **MATLAB is trademark of The MathWorks**. Disponível em: <<http://www.mathworks.com>>. Acesso em: junho 2006.

METROPOLIS, N.; ULAM, S. The Monte Carlo Method. **Journal of the American Statistical Association**, [S.l.], v.247, n.44, p.335–341, 1949.

NUMMIARO, K.; KOLLER-MEIER, E.; GOOL, L. Object Tracking with an Adaptive Color-Based Particle Filter. In: DAGM SYMPOSIUM ON PATTERN RECOGNITION, 2002, Zurich, Switzerland. **Proceedings...** Berlin: Springer, 2002. p.353 – 360. (Lecture Notes in Computer Science, v.2449).

PÉREZ, P. et al. Color-based probabilistic tracking. In: EUR. CONF. ON COMPUTER VISION, ECCV'2002, 2002, Copenhaguen, Denmark. **Proceedings...** Berlin: Springer, 2002. p.661–675. (Lecture Notes in Computer Science, v.2350).

RIBEIRO, M. I. **Kalman and Extended Kalman Filters: concept, derivation and properties.** Portugal: [s.n.], 2004.

SATOH, Y.; OKATANI, T.; DEGUCHI, K. A Color-based Tracking by Kalman Particle Filter. In: INTERNATIONAL CONFERENCE ON PATTERN RECOGNITION, 17., 2004. **Proceedings...** [S.l.: s.n.], 2004.

SCHON, T. **On Computational Methods for Nonlinear Estimation.** 2003. Tese (Doutorado em Ciência da Computação) — Linkoping Universitet, Sweden.

TRIVEDI, K. S. **Probability and Statistics with Reliability, Queuing, and Computer Science Applications.** Englewood Cliffs: Prentice Hall, 1982.