

Rastreamento Visual de Múltiplos Objetos Baseado em Contornos Aplicado ao Futebol de Robôs

Rodrigo Andrade de Bem¹, Anna Helena Reali Costa¹

¹Laboratório de Técnicas Inteligentes – Escola Politécnica da USP
Av. Prof. Luciano Gualberto, trav.3, n.158, Cidade Universitária
05508-900 - São Paulo, SP, Brasil

{rodrigo.bem,anna.reali}@poli.usp.br

Abstract. *This paper presents a methodology applied to robot soccer for the visual tracking of multiple targets in video using a static camera. The objective in this approach is to track the objects described by their contours, instead of using only the usual color information, which is normally noisy. The tracking process is decomposed into two Kalman Filters instantiated for each target: one for the contour shape estimation and one for the motion estimation. The observation model is based on the intensity edges of the images, extracted along measurement lines fixed in the contours. The use of this model reduces the analysis of a 2D image to the analysis of several 1D lines. Results presented in the experiments show that the proposed tracking methodology may lead to good performance.*

Resumo. *Este trabalho apresenta uma metodologia, aplicada ao futebol de robôs, para o rastreamento visual de múltiplos alvos em seqüências de imagens usando uma câmara estática. O objetivo é rastrear os objetos descritos por seus contornos, ao invés de utilizar apenas a informação de cor, frequentemente ruidosa. O processo de rastreamento é executado através de dois Filtros de Kalman instanciados para cada alvo: um para estimação da forma do contorno e outro para estimação do movimento. O Modelo de observação é baseado em bordas de intensidade extraídas ao longo de linhas de medida fixas nos contornos. O uso deste modelo reduz a análise de uma imagem 2D para a análise de várias linhas 1D. Os resultados obtidos nos experimentos mostram que a metodologia proposta pode levar a um bom desempenho na solução do problema.*

1. Introdução

Partidas de futebol entre robôs constituem uma atividade que possibilita a realização de experimentos reais, dando suporte ao desenvolvimento e testes de algoritmos que viabilizam que robôs móveis tenham um comportamento autônomo, eficiente, cooperativo, com capacidades de planejamento, raciocínio e aprendizado, e sob restrições de tempo real [Veloso et al. 1998], [Tambe 1998]. Nacionalmente as categorias mais populares são a *IEEE Very Small Size Robot Soccer* [IEEE 2006] e a *RoboCup Soccer Small-Size League (F-180)* [RoboCup 2006]. Apesar de apresentarem entre si variações quanto às dimensões do campo e dos jogadores, as duas categorias possuem em suas regras definições comuns, como a utilização de uma câmara global, posicionada acima do campo, para aquisição das imagens, e a possibilidade do processamento ser executado externamente aos robôs em um computador.

O funcionamento de cada time segue uma mesma seqüência básica: aquisição da imagem através da câmera global, processamento usando técnicas de visão computacional para descobrir a posição de todos os robôs e da bola, decisão da melhor tática a ser aplicada, envio dos comandos por rádio frequência ao time e por fim, execução dos movimentos pelos robôs. Usualmente cada robô dentro de um mesmo time é diferenciado através de marcas coloridas fixadas sobre os mesmos. Na identificação de cada componente do time, variações de iluminação, restrição de espaço sobre os robôs e necessidade de escolha de cores totalmente distintas são problemas frequentemente encontrados. Neste contexto, a utilização de um algoritmo de rastreamento visual de múltiplos objetos, eficiente e de baixo custo computacional, capaz de manter a identidade dos objetos ao longo do jogo, pode representar uma economia significativa de tempo de processamento em cada iteração, e uma facilitação do processo.

Baseado no fato de, no contexto tratado, os movimentos dos alvos serem limitados pelo plano do campo e não haver mudanças de escala (já que a câmera é estática e perpendicular ao campo), o presente trabalho contribui com uma metodologia probabilística para o rastreamento de múltiplos alvos nas imagens capturadas pela câmera do futebol de robôs. A abordagem empregada descreve os alvos através de seus contornos, mas sem a determinação *a priori* de sua forma, o que possibilita o rastreamento simultâneo de objetos com formatos diferentes nas imagens, como por exemplo, vários robôs móveis heterogêneos. O modelo de observação é baseado nas bordas de intensidade extraídas sobre linhas de medida posicionadas ao longo dos contornos [Blake and Isard 1998]. Isto reduz a análise de uma imagem 2D a uma série de linhas de medida 1D [MacCormick and Blake 2000]. A estimação da forma do contorno e do movimento são executadas separadamente por dois Filtros de Kalman [Gelb et al. 1974] instanciados para cada alvo [Koller et al. 1994].

A abordagem proposta tem início com a segmentação dos alvos (robôs e bola) através da subtração da cena de fundo nas duas primeiras imagens da seqüência; os objetos segmentados, correspondentes aos alvos, são identificados como pertencentes a um time ou outro (ou como a bola), por suas cores na imagem, como será descrito na Seção 2. As mesmas áreas segmentadas, correspondentes aos objetos, são usadas para construção de uma estimativa inicial de seus contornos, como será detalhado na Seção 3; além da derivada temporal discreta da posição de seus centróides, na primeira e segunda imagens, ser empregada na inicialização dos parâmetros usados pelos Filtros de Kalman. A partir da terceira imagem da seqüência, o processo de rastreamento propriamente dito inicia-se, no qual os alvos não são mais segmentados, e sim rastreados através da estimativa de seus contornos. A cada iteração um Filtro de Kalman realiza a predição do movimento, com base no modelo de movimento que será visto na Seção 4, e o outro a predição da forma do contorno de cada alvo; tais predições são atualizadas com o uso do modelo de observação, descrito na Seção 3. Os Filtros de Kalman usados são descritos na Seção 5. Na Seção 6 são apresentados os experimentos e resultados alcançados, e finalmente, a Seção 7 apresentada as conclusões e trabalhos futuros.

2. Segmentação dos Alvos

A subtração da cena de fundo, um método simples de segmentação de movimento amplamente difundido na literatura, foi utilizado, visto que a câmera permanece estática. Em situações em que não é possível a aplicação da subtração da cena de fundo, o método de

diferenciação entre imagens subsequentes pode ser usado.

Após esta primeira operação, uma série de técnicas de processamento digital de imagens são aplicadas, visando a determinação das áreas correspondentes aos alvos com o mínimo possível de ruído. Inicialmente é utilizado um filtro espacial gaussiano sobre o resultado da subtração, buscando eliminar ruídos impulsivos. Em seguida a imagem é binarizada e submetida às operações morfológicas abertura de área e abertura que, respectivamente, eliminam componentes isolados com áreas muito menores do que a área dos alvos, e saliências de espessura reduzida, mesmo que estejam ligadas aos alvos. Na Figura 1 pode-se ver o resultado de cada operação na segmentação de alvos sintéticos.




Figura 1. Resultado da aplicação do: (a) filtro gaussiano; (b) limiar para binarização; (c) operador morfológico de abertura de área; (d) operador morfológico de abertura.

Para identificar os objetos segmentados como pertencentes a um time ou outro (além da bola), a informação de cor é utilizada. Esta é uma importante evidência para detecção de objetos em imagens, robusta quanto à oclusão, mudanças de escala, rotação e mudanças de resolução. Um sinal RGB pertence a um espaço de cores 3D, onde cada pixel é um ponto no espaço. Os pixels de um determinado objeto formam uma distribuição neste espaço de cores, a qual pode ser modelada estimando-se uma função de densidade de probabilidade. Para contornar problemas de variação de iluminação, os pixels foram projetados no espaço de cores HSV (*hue-saturation-value*), no qual a intensidade é isolada na banda V. Com isso, a distribuição no espaço 2D HS, tem um grau de constância em relação a alterações de iluminação [Gong et al. 2000].

O método do histograma foi escolhido para estimação das densidade de probabilidade [Costa and Cesar 2000], por não haver muitos indícios sobre a forma da função de densidade de probabilidade dos objetos, sendo que o uso de um método paramétrico poderia prejudicar a modelagem. Além disso, trata-se de um método simples de ser empregado, havendo a possibilidade de uso de um bom número de amostras. A classificação é feita determinando-se o time ao qual um objeto tem maior probabilidade de pertencer, de acordo com a densidade de probabilidade estimada. Este método é chamado de máximo *a posteriori* (MAP) [Costa and Cesar 2000]. A Figura 2 mostra um exemplo de um histograma de cores usado na estimação.

Para cada área segmentada (alvo móvel) é definida uma região de interesse descrita por um quadrilátero englobando toda área, que será usada para definição do contorno do objeto, como será visto na seção seguinte. Além disso, cada área é identificada como

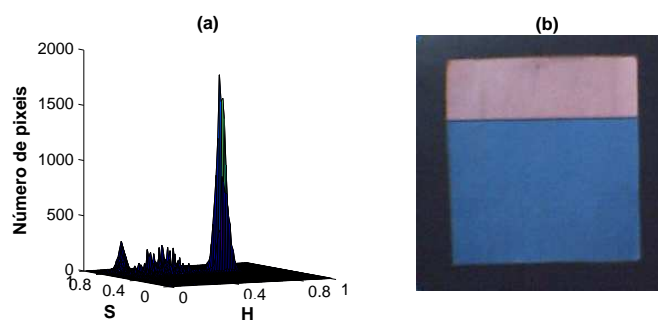


Figura 2. (a) Histograma de cores, no espaço HS, da imagem com o exemplo da vista das marcas no topo de um robô, mostrada em (b).

correspondente a um dos times do jogo, de acordo com a sua cor, e esta identificação será mantida no processo de rastreamento. A partir deste ponto do processo, o modelo de observação baseado nos contornos será usado para extrair informações das imagens.

3. Modelo de Observação

Neste trabalho, os alvos são descritos por seus contornos, modelados como *B-splines* quadráticas [Blake and Isard 1998]. Com o objetivo de rastrear objetos com formas heterogêneas, nenhum modelo de contorno é estabelecido *a priori*. Ao invés disso, o modelo inicial de cada alvo é determinado através da segmentação dos objetos móveis nas duas primeiras imagens da seqüência, com descrito na Seção 2. São definidos então alguns pontos de controle, igualmente espaçados ao longo do perímetro da região de interesse, que serão utilizados para construção da estimativa inicial do contorno do alvo. A Figura 3 mostra o quadrilátero envolvente da região de interesse, os pontos de controle e as linhas de medida definidos.




Figura 3. Dois alvos sintéticos sobre os quais foram definidos: em (a) a região de interesse segmentada (linha branca) e os pontos de controle ao longo de seu perímetro (pontos pretos); em (b) as linhas de medida construídas sobre os pontos de controle, e o contorno dos alvos.

Os pontos de controle definem a configuração do contorno do alvo. Uma configuração de um contorno $\vec{X} \in \mathcal{S}$, onde \mathcal{S} é um espaço vetorial de *B-splines* de dimensões reduzidas, é dada por $\vec{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)^T$, onde $\mathbf{x}_i = (x_i, y_i)$ é um ponto de controle, com $i \in \{1, \dots, n\}$.

Com o objetivo de reduzir o custo computacional e o tempo de processamento, a observação dos alvos nas imagens é realizada através de linhas de medida posicionadas nos pontos de controle do contorno, como visto na Figura 3. Esta abordagem reduz o problema de analisar a imagem 2D à análise de uma série de linhas 1D

[MacCormick and Blake 2000]. Um detector de bordas unidimensional (filtro passa-alta) é aplicado a cada uma das linhas de medida, localizando alterações bruscas na intensidade dos *pixels*. Mais de uma borda pode ser detectada em uma linha de medida, quando há fundo de cena heterogêneo, sombras em torno do objeto de interesse ou oclusão entre os alvos. Optou-se por um método probabilístico simples e eficaz que se adapta melhor ao Filtro de Kalman empregado no rastreamento dos alvos.

Considere uma linha de medida $\mathbf{z} = (z_1, z_2, \dots, z_m)$, onde z_j é uma variação de intensidade (borda) detectada, com $j \in \{1, \dots, m\}$. A probabilidade de z_j corresponder ao contorno real do objeto é dada pela distribuição de probabilidade $\mathcal{G}(z_j|\nu)$, sendo \mathcal{G} uma gaussiana com centro em ν , que é a posição do ponto de controle na linha de medida, e desvio padrão σ , que representa a incerteza nesta posição (são usadas apenas as posições unidimensionais dos pontos na linha de medida) [Blake and Isard 1998]. A característica z_j correspondente à borda real do alvo em cada linha de medida é determinada pela hipótese de máximo *a posteriori* (MAP), ou seja, aquela que apresentar maior probabilidade, dada a posição do ponto de controle. Uma ilustração da densidade de probabilidade gaussiana sobre a linha de medida é mostrada na Figura 4.




Figura 4. (a) Uma linha de medida, extraída da imagem na Figura 3(a). (b) Resultado da aplicação do detector de bordas 1D. (c) Densidade de probabilidade gaussiana. (d) Probabilidade de cada *pixel* corresponder à borda real (mais escuro=maior probabilidade).

4. Modelo de Movimento

O objetivo aqui foi estabelecer um modelo de movimento único e simples, aplicável a todos os alvos, utilizando poucas informações *a priori*. Considerando o campo de visão usado, alvos com movimentos limitados pelo plano do campo e independentes entre si, as alterações de velocidade e de forma dos móveis na sequência de imagens podem ser aproximadas por transformações lineares [Koller et al. 1994].

Sendo $\mathbf{x} = (x, y)$ um ponto da imagem localizado em uma área correspondente a um alvo, o movimento $m(\mathbf{x})$ neste ponto pode ser aproximado por:

$$m(\mathbf{x}) = A(\mathbf{x} - \mathbf{c}) + \mathbf{u}, \quad (1)$$

onde $\mathbf{c} = (c^x, c^y)$ é o centro da área, $\mathbf{u} = (v_x, v_y)$ é o deslocamento de \mathbf{c} nas direções x e y , respectivamente, e A a matrix de rotação e mudança de escala. Devido ao fato da câmera estar fixa sobre o campo, e os alvos terem seus movimentos limitado pelo plano do chão, não há mudança de escala real, no entanto, movimentos de rotação suaves que produzem alterações na forma do contorno do objeto, e são apenas possíveis em relação

ao eixo normal ao plano, são modelados como pequenas alterações de escala. No caso de robôs com formato quadrado, isto é visível quando o mesmo executa uma rotação de, por exemplo, 90 graus; nesse caso o movimento gera uma alteração na forma, que pode ser considerada como uma mudança de escala do contorno. Dessa maneira, considerando-se que há pouca alteração do alvo entre quadros consecutivos, a matriz A fica restrita a mudanças de escala. Assim, a equação 1 é reduzida para:

$$m(\mathbf{x}) = s(\mathbf{x} - \mathbf{c}) + \mathbf{u}, \quad (2)$$

onde s é o fator de escala. O valor de $s = 0$ significa que não há mudança de escala, enquanto $s < 0$ corresponde à diminuição e $s > 0$, ao aumento da área estimada do objeto, envolvida pelo contorno.

Dessa forma, a translação e a mudança de escala dos alvos na seqüência de imagens são representadas por \mathbf{u} e s . A predição correta destes parâmetros do modelo de movimento corresponde à primeira derivada temporal dos mesmos. No entanto essas derivadas são corrompidas por medidas ruidosas, o que pode tornar a predição instável e errônea. Localmente pode-se supor simplesmente que \mathbf{u} e s são constantes, sendo as pequenas alterações esperadas nesses parâmetros, devido ao fato dos movimentos serem suaves, modeladas através do ruído no processo de estimação [Koller et al. 1994].

5. Rastreamento com Filtro de Kalman

O rastreamento dos alvos é realizado com o emprego de dois Filtros de Kalman: um para estimação do movimento, e outro para estimação da forma do contorno de cada alvo. Esta abordagem é adotada para que o sistema permaneça linear de modo que o Filtro de Kalman seja empregado com sucesso no processo de estimação [Koller et al. 1994]. Os vetores de estado que descrevem o sistema são dados por

$$\begin{aligned} \vec{X} &= (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)^T = (x_1, y_1, x_2, y_2, \dots, x_n, y_n)^T, \\ \vec{M} &= (\mathbf{u}, s)^T = (v_x, v_y, s)^T, \end{aligned} \quad (3)$$

sendo \vec{X} o vetor de estado do contorno, definido por seus pontos de controle \mathbf{x}_i , com $i \in \{1, \dots, n\}$; e \vec{M} o vetor de estado do movimento do alvo, definido pela velocidade de translação \mathbf{u} e o fator de escala s . Considerando a equação 2 para um ponto de controle, com $m(\mathbf{x}) = \mathbf{x}_{i,k} - \mathbf{x}_{i,k-1}$, tem-se:

$$\mathbf{x}_{i,k} = \mathbf{x}_{i,k-1} + s_{k-1}(\mathbf{x}_{i,k-1} - \mathbf{C}_{i,k-1}) + \mathbf{u}_k, \quad (4)$$

onde o índice k denota o tempo t_k e $\mathbf{C}_{i,k-1} = (C_{i,k-1}^x, C_{i,k-1}^y)^T$ corresponde ao centro de todos os pontos de controle do alvo i , o qual estima o centro de área do alvo. A equação 4, que define a posição que será ocupada pelo ponto de controle $\mathbf{x}_{i,k-1}$ no tempo k , pode ainda ser escrita matricialmente para o contorno de um alvo como:

$$\begin{aligned} \vec{X}_k &= \vec{X}_{k-1} + H_{k-1} \vec{M}_k, \text{ com} \\ H_{k-1} &= \begin{pmatrix} I_2 & (\mathbf{x}_{1,k-1} - \mathbf{C}_{1,k-1}) \\ \vdots & \vdots \\ I_2 & (\mathbf{x}_{n,k-1} - \mathbf{C}_{n,k-1}) \end{pmatrix}, \end{aligned} \quad (5)$$

sendo I_2 uma matriz identidade de dimensão 2×2 .

Os sistemas de estimação do movimento e forma serão apresentados nas duas próximas seções, respectivamente.

5.1. Estimação de Movimento

Como mencionado na Seção 4, os parâmetros que compõem o vetor de estado do movimento do alvo são considerados localmente constantes. Assim, o sistema é descrito pelas seguintes equações:

$$\begin{aligned}\vec{M}_k &= \vec{M}_{k-1} + \vec{q}_{k-1} \\ \vec{Z}_k &= (X_{k-1} + H_{k-1}\vec{M}_k) + \vec{v}_k,\end{aligned}\quad (7)$$

onde, no tempo k , \vec{q} é uma variável aleatória gaussiana, representando o ruído do processo de estimação, com média zero e covariância Q : $\vec{q} \sim \mathcal{N}(0, Q)$; \vec{Z}_k é o vetor de observação do sistema; e \vec{v} é uma variável aleatória gaussiana, representando o ruído da observação, com média zero e covariância R : $\vec{v} \sim \mathcal{N}(0, R)$. O vetor de observação \vec{Z}_k corresponde à posição dos pontos de controle do contorno acrescida do ruído da observação.

O Filtro de Kalman é um estimador recursivo Bayesiano que a cada iteração executa três etapas: predição, assimilação e atualização. Uma vez que o filtro é um estimador gaussiano linear, a distribuição de probabilidade sobre o vetor de estado \vec{M}_k é totalmente definida pela média $\overline{\vec{M}}_k$ e pela matriz de covariância $P_{M,k}$ [Gelb et al. 1974]. Assim, o processo de estimação é dado pelas seguintes equações características do Filtro de Kalman:

- *Predição*

$$\begin{aligned}\overline{\vec{M}}'_k &= \overline{\vec{M}}_{k-1} \\ P'_{M,k} &= P_{M,k-1} + Q_{k-1}\end{aligned}$$

- *Assimilação (Cálculo do Ganho de Kalman)*

$$K_k = P'_{M,k} H_{k-1}^T (H_{k-1} P'_{M,k} H_{k-1}^T + R_k)^{-1}$$

- *Atualização*

$$\begin{aligned}\overline{\vec{M}}_k &= \overline{\vec{M}}'_k + K_k(\vec{Z}_k - (X_{k-1} + H_{k-1}\overline{\vec{M}}'_k)) \\ P_{M,k} &= (I - K_k H_{k-1}) P'_{M,k}\end{aligned}$$

5.2. Estimação da Forma

A estimação do contorno rastreia os n pontos de controle do alvo e é modelada como:

$$\begin{aligned}\vec{X}_k &= (\vec{X}_{k-1} + H_{k-1}\overline{\vec{M}}_k) + \vec{w}_{k-1} \\ \vec{Z}_k &= \vec{X}_k + \vec{v}_k,\end{aligned}\quad (8)$$

onde \vec{w} é uma variável aleatória gaussiana, representando o ruído na estimação, com média zero e covariância W : $\vec{w} \sim \mathcal{N}(0, W)$; \vec{Z}_k é o vetor de observação do sistema; e \vec{v} representa o ruído da observação, como mencionado anteriormente.

As etapas do Filtro de Kalman são definidas como:

- *Predição*

$$\begin{aligned}\overline{\vec{X}}'_k &= \overline{\vec{X}}_{k-1} + H_{k-1}\overline{\vec{M}}_k \\ P'_{X,k} &= P_{X,k-1} + W_{k-1}\end{aligned}$$

- *Assimilação (Cálculo do Ganho de Kalman)*

$$K_k = P'_{X,k}(P'_{X,k} + R_k)^{-1}$$

- *Atualização*

$$\begin{aligned}\bar{\vec{X}}_k &= \bar{\vec{X}}'_k + K_k(\bar{\vec{Z}}_k - \bar{\vec{X}}'_k) \\ P_{X,k} &= (I - K_k)P'_{X,k}\end{aligned}$$

5.3. Inicialização do Sistema

A inicialização do sistema começa pela segmentação dos alvos que é executada conforme descrito na Seção 2. São definidos os n pontos de controle, utilizados na construção da estimativa inicial do contorno do alvo, $\bar{\vec{X}}_{k=0}$.

No caso do vetor de estado de movimento, o fator de escala é inicialmente definido como $s = 0$, uma vez que este parâmetro será sempre muito pequeno. Já no caso das velocidades horizontal e vertical, a derivada temporal discreta do centróide de cada alvo segmentado é usada, sendo $\mathbf{u}_{k=0} = (\mathbf{c}_k - \mathbf{c}_{k-1})$, assim $\bar{\vec{M}}_{k=0} = (c_k^x - c_{k-1}^x, c_k^y - c_{k-1}^y, s = 0)^T$. Salienta-se que o instante $t_k = 0$ do rastreamento é correspondente à segunda imagem da seqüência, já que a primeira ($t_k = -1$) é apenas usada na inicialização para o cálculo das derivadas discretas.

A correspondência entre as áreas segmentadas na primeira e segunda imagens é estabelecida através da determinação do vizinho mais próximo, de acordo com a suposição que os alvos executam movimentos suaves.

6. Experimentos e Resultados

Foram realizados experimentos com seqüências de imagens de uma partida de futebol de robôs, com dimensões de 352 por 240 *pixels*, capturadas com uma câmera estática sobre o campo. Todos os robôs componentes de um dos times possuem como marca visual um quadrado amarelo claro sobre si, e foram identificados por essa cor na segmentação dos alvos, como descrito na Seção 2. Apenas esse time foi rastreado nas imagens, já que os robôs do outro time possuem marca individuais, o que dificulta sua identificação, como mencionado anteriormente. Os robôs realizaram movimentos suaves de translação e rotação sobre o fundo de cena uniforme em uma seqüência de 400 imagens. Na Figura 5, são mostradas amostras da seqüência e as trajetórias dos robôs marcadas nas imagens.

O Filtro de Kalman foi inicializado conforme descrito na Seção 5.3. Foram utilizados $n = 12$ pontos de controle, linhas de medidas de comprimento $L = 14$, desvio padrão $\sigma = 3$ *pixels* e a máscara de convolução de detector de bordas 1D com pesos $[-1, 2; -2; 0; 2; 1, 2]$. A covariância do ruído de observação foi definida como $v = 0,4$ *pixels* para cada ponto de controle, e nos processos de estimação como $q_u = 0,001$ para o movimento de translação, $q_s = 10^{-8}$ para a mudança de escala e $w = 0,001$ para estimação da forma. Na Figura 6 são mostradas as coordenadas reais do centróide de cada alvo, obtidas com a subtração do fundo em cada imagem em todas as imagens, em comparação com as coordenadas estimadas. O erro quadrático médio (EQM) para cada alvo foi: alvo **A**, $EQM_A = 33,38$; alvo **B**, $EQM_B = 5,41$ e alvo **C**, $EQM_B = 14,43$. Esse erros equivalem aproximadamente a 6, 2 e 4 *pixels* nas imagens.

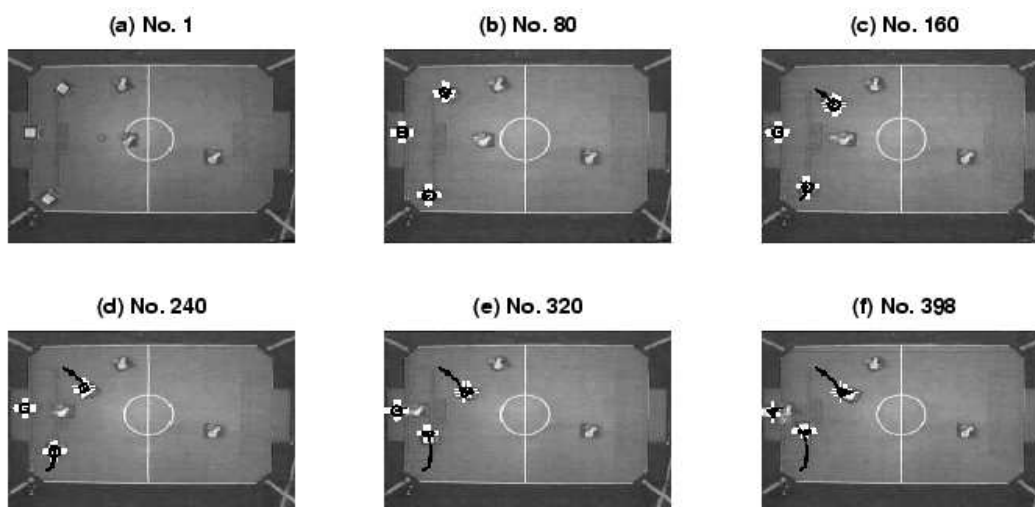


Figura 5. Os 3 alvos à esquerda, identificados por quadrados amarelo claro, de baixo para cima são rotulados como alvos B, A e C, e têm suas trajetórias marcadas nas imagens. O número acima de cada imagem identifica sua posição na seqüência.

7. Conclusões e Trabalhos Futuros

Como visto na seção anterior, a abordagem teve um desempenho satisfatório nos experimentos realizados. Na Figura 5, pode-se ver que o rastreador seguiu os robôs móveis do início ao fim da seqüência, mantendo uma boa estimativa da posição de seus centróides, como comprova a Figura 6, com o maior valor do erro quadrático médio ($EQM_A = 33,38$) correspondendo a aproximadamente 6 *pixels* nas imagens, o que é aceitável já que continua sobre o robô, que tem uma dimensão em torno de 19×19 *pixels* nas imagens. A metodologia faz uso da informação de cor, extraída de uma marca visual idêntica para todos os robôs de um mesmo time, apenas na sua inicialização, constituída pela segmentação dos alvos.

Assim, pode-se concluir que a abordagem proposta, constituída pelo modelo de observação apresentado, bem como o modelo de movimento, e o processo de estimação, foi eficaz na solução do problema nos experimentos realizados, considerando as suposições e limitações mencionadas anteriormente. Como trabalhos futuros serão aprimorados os modelos de observação e de movimento, visando permitir a execução de movimentos mais rápidos e alterações bruscas de direção. A avaliação do desempenho da abordagem em tempo-real também será realizada por meio de mais experimentos.

8. Agradecimentos

Rodrigo A. de Bem agradece ao Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq, entidade governamental brasileira promotora do desenvolvimento científico e tecnológico, pelo suporte financeiro através do processo número 132185/2005-9. Trabalho conduzido sob o projeto MultiBot CAPES/GRICES processo número 099/03.




Figura 6. Comparação entre a posição real dos centróides (linhas contínuas) e a posição estimada (linhas pontilhadas) para os três alvos.

Referências

- Blake, A. and Isard, M. (1998). *Active Contours*. Springer-Verlag.
- Costa, L. and Cesar, R. M. (2000). *Shape Analysis and Classification*. CRC Press.
- Gelb, A., Kasper, J. F., Nash, R. A., Price, C. F., and Sutherland, A. A. (1974). *Applied Optimal Estimation*. The MIT Press.
- Gong, S., McKenna, S. J., and Psarrou, A. (2000). *Dynamic Vision - From Images to Face Recognition*. Imperial College Press.
- IEEE (2006). Ieee latin-american students robotics competition - rules for the very small category. URL: <http://www.robopuc.cl/larc/documents/LARC-2006-verysmallsize.pdf>. Acessado em 19/04/06.
- Koller, D., Weber, J., and Malik, J. (1994). Robust multiple car tracking with occlusion reasoning. Working Paper UCB-ITS-PWP-94-1, California Path Program, Inst. of Transportation Studies, Univ. of California, Berkeley.
- MacCormick, J. and Blake, A. (2000). Probabilistic exclusion principle for tracking multiple objects. *Int. Journal of Computer Vision*, 1(39):57–71.
- RoboCup (2006). The robocup federation - regulations and rules. URL: <http://www.robocup.org/regulations/4.html>. Acessado em 19/04/06.
- Tambe, M. (1998). Implementing agent teams in dynamic multi-agent environments. *Applied Artificial Intelligence*, 12.
- Veloso, M., Stone, P., and Han, K. (1998). The cmunited-97 robotic soccer team: Perception and multiagent control. In *Proc. Int. Conf. on Autonomous Agents*, volume 2, pages 283–292, Minneapolis.