

RASTREAMENTO DE LARVAS DO MOSQUITO *Aedes Aegypti* UTILIZANDO FILTRO DE KALMAN E ASSOCIAÇÃO PROBABILÍSTICA CONJUNTA

ANDRÉ PEREIRA GARCIA*, VALGUIMA VICTORIA VIANA AGUIAR ODAKURA†

**Departamento de Computação e Estatística – DCT*
Universidade Federal de Mato Grosso do Sul – UFMS, Mato Grosso do Sul, Brasil

†*Faculdade de Ciências Exatas e Tecnologia – FACET*
Universidade Federal da Grande Dourados – UFGD, Mato Grosso do Sul, Brasil

Emails: andre.garcia@tecsinapse.com.br, valguimaodakura@ufgd.edu.br

Abstract— In this paper it is presented a solution to multiple *Aedes Aegypti* larvae tracking based on Kalman filter and joint probabilistic data association. The approach has been tested with simulated values and real values extracted from images from a video camera. In all experiments, the method used presented promising larvae tracking results.

Keywords— Tracking, Kalman filter, Computational Vision, Larvae.

Resumo— Neste artigo é apresentada uma solução para o rastreamento de múltiplas larvas do mosquito *Aedes Aegypti* baseada no filtro de Kalman e na associação de dados probabilística conjunta. Foram realizados experimentos com dados simulados e com dados reais, extraídos de imagens das larvas captadas por uma câmera. Em todos os experimentos, a técnica empregada apresentou resultados bastante promissores no rastreamento de larvas.

Palavras-chave— Rastreamento, filtro de Kalman, Visão Computacional, Larvas.

1 Introdução

O mosquito *Aedes Aegypti* é o vetor de doenças como a dengue e a febre amarela. Atualmente a dengue tem causado preocupação no Brasil devido ao alto número de epidemias que surgiram em várias regiões do país. Esta situação tem motivado muitas pesquisas na busca de um novo inseticida que cause a morte do mosquito, ainda em sua fase larval, sem prejudicar ao homem e ao meio ambiente.

Os experimentos com os novos extratos de planta consistem em realizar observações das larvas submetidas a concentrações diferentes, diluídas em água, de um mesmo extrato. Cada teste é submetido a uma observação contínua por parte de um especialista ao longo de 24h, sendo que durante este tempo são coletadas informações como a quantidade de larvas mortas e o instante das mortes. O objetivo deste teste é encontrar a concentração do extrato ideal que tenha uma taxa de mortalidade de larvas adequada. A necessidade de observação pessoal ao longo de 24h, torna os resultados suscetíveis a erros humanos devido a vários fatores como estresse e fadiga.

Este problema faz parte do projeto de pesquisa LARVIC – Rastreamento de Múltiplas Larvas utilizando técnicas de Visão Computacional¹ - que tem como objetivo automatizar a parte de monitoração dos experimentos através da captura de imagens das larvas e utilização de técnicas algorítmicas de segmentação de imagem, rastreamento e classificação para gerar automaticamente a taxa de mortalidade das larvas. A Figura 1(a) ilustra a

estrutura do experimento, com câmera e pote de larvas e a Figura 1(b) mostra imagens de 4 potes com larvas captadas por uma câmera.

O presente artigo visa tratar tão somente do módulo de rastreamento das larvas, sendo que a entrada para este módulo é fornecida pelo módulo de segmentação das imagens e a saída é utilizada como entrada para o módulo de classificação. A identificação das larvas mortas e vivas é dada através de movimento das mesmas, uma vez que as larvas vivas necessariamente precisam se movimentar para respirar. Desta forma, técnicas de rastreamento das larvas podem auxiliar na detecção da taxa de mortalidade, através da observação da posição das larvas em quadros subsequentes de imagens. Técnicas de rastreamento utilizando informações visuais tem sido utilizadas com sucesso em diversos domínios de aplicação, como no rastreamento de camundongos (Gonçalves et al., 2007) ou pessoas (Liebens et al., 2006).

Este artigo está organizado da seguinte forma. Na Seção 2 o filtro de Kalman é brevemente introduzido e em seguida é apresentado o método de associação de dados probabilística conjunta utilizado para o rastreamento de múltiplas larvas. Na Seção 3 os experimentos realizados são descritos e discutidos. Por fim, as conclusões são apresentadas na Seção 4.

2 Rastreamento de múltiplos alvos

O filtro de Kalman – FK foi publicado pela primeira vez por Kalman, (Kalman, 1960), como uma solução recursiva para o problema de filtragem linear de sistemas discretos. O filtro de Kalman é

¹<http://www.gpec.ucdb.br/projetos/larvic/>




Figura 1: (a) Visão do experimento: câmera e pote com larvas. (b) Imagens de 4 potes com 10 larvas cada.

um conjunto de equações matemáticas que possibilita estimar recursivamente o estado de um sistema linear, com variância mínima segundo um dado critério de otimalidade. O FK é um dos métodos mais conhecidos e usados para rastreamento de alvos (Cuevas et al., 2005), (Liebens et al., 2006). O filtro de Kalman realiza a estimação de estado do sistema utilizando toda informação disponível: todas as observações realizadas, bem como o conhecimento sobre os modelos de movimento e observação. As informações de interesse no sistema podem ser representadas por um vetor de estado x_k , n -dimensional, no tempo k .

Os modelos de movimento do alvo e de observação são dados, respectivamente, por:

$$x_{k+1} = F_k x_k + w_k, \quad (1)$$

$$y_k = H_k x_k + v_k, \quad (2)$$

onde F_k é uma função de transição de estado e w_k é o vetor de ruído do movimento, e H_k é a matriz de observação, que relaciona o vetor de estado x_k com o vetor de observações y_k , e v_k é o vetor de ruído das observações.

O filtro de Kalman opera em um ciclo de predição-atualização. Na fase de predição, a posição do alvo e as observações são estimadas num tempo futuro utilizando o modelo de movimento e o modelo de observação, respectivamente:

$$\hat{x}_{k+1|k} = F_k \hat{x}_{k|k}, \quad (3)$$

$$P_{k+1|k} = F_k P_{k|k} F_k^T + Q_k, \quad (4)$$

$$\hat{y}_{k+1|k} = H_k \hat{x}_{k+1|k}, \quad (5)$$

onde a matriz $P_{k+1|k}$ é a matriz de covariância da posição, que representa a incerteza da estimação $\hat{x}_{k+1|k}$ e $\hat{y}_{k+1|k}$ é a predição das observações.

As observações reais y_{k+1} são correspondidas com as observações previstas $\hat{y}_{k+1|k}$, selecionando as observações válidas. Para validar uma observação, utiliza-se: $z_{k+1} S_{k+1}^{-1} z_{k+1}^T \leq \alpha$, para um dado limiar α , onde:

$$z_{k+1} = y_{k+1} - \hat{y}_{k+1|k}, \quad (6)$$

$$S_{k+1} = H_{k+1} P_{k+1|k} H_{k+1}^T + R_{k+1}. \quad (7)$$

Na atualização, a predição da posição é corrigida utilizando as observações válidas:

$$\hat{x}_{k+1|k+1} = \hat{x}_{k+1|k} + G_{k+1} z_{k+1}, \quad (8)$$

$$P_{k+1|k+1} = P_{k+1|k} - G_{k+1} S_{k+1} G_{k+1}^T, \quad (9)$$

$$G_{k+1} = P_{k+1|k} H_{k+1}^T S_{k+1}^{-1}. \quad (10)$$

A matriz G_{k+1} é o ganho de Kalman, que é utilizado para ponderar a inovação entre as observações previstas e reais.

O FK realiza a tarefa de rastrear alvos de maneira ótima caso estes possuam modelos de movimento e observação lineares. Entretanto modelos lineares são extremamente raros de serem compatíveis com a movimentação de qualquer alvo, assim é necessária a utilização de modelos não-lineares, que perdem a propriedade de otimalidade do FK, e levam a sua versão estendida, o filtro de Kalman Estendido – FKE (Maybeck, 1979).

2.1 Associação de Dados Probabilística Conjunta

O filtro de Kalman atende bem a tarefa de rastrear um único alvo. No entanto, o que ocorre quando é necessário rastrear mais de um alvo simultaneamente no mesmo espaço de busca? Uma resposta é criar uma instância do filtro de Kalman para cada um dos alvos, assim cada filtro fica responsável por rastrear um alvo diferente. Esta é uma abordagem muito boa, porém deve-se atentar para um detalhe em especial na fase de atualização do filtro. Para atualização do filtro é necessário distinguir qual alvo emitiu qual observação. Se os alvos não puderem ser identificados, pode-se supor que cada observação pode ter sido emitida por qualquer alvo. No caso das larvas é exatamente isto que ocorre, não é possível distinguir uma larva da outra na imagem.

No entanto, algumas observações são mais prováveis de pertencer a um determinado alvo que outras, mas mesmo assim é comum haver mais de um possível alvo para uma dada observação (Liebens et al., 2006). Aliado a isto, tem-se ainda outros problemas como o fato de o alvo não ter gerado nenhuma observação naquele intervalo de tempo ou ainda a possibilidade de se obter mais observações do que alvos. Foram desenvolvidos muitos métodos para se tentar fazer a atribuição observação-alvo do modo mais eficiente possível (Kirubarajan and Bar-Shalom, 2004), (Fortmann et al., 1983), (Kalandros and Pao, 2001) e (Fortmann et al., 1980).

A Associação de Dados Probabilística Conjunta (*Joint Probabilistic Data Association*) – JPDA é um método de casamento de dados que tem como idéia básica que todas as observações podem ter sido geradas por um determinado alvo. Para cada observação, é calculada a probabilidade do alvo pertencer a esta observação, ou seja, a

observação associada ao alvo é uma observação abstrata contruída a partir da soma de todas as observações ponderadas com a probabilidade calculada. Desta forma, todas as observações contribuem para a atualização da predição do alvo, porém as observações que tem mais chance de serem pertencentes ao alvo tem uma influência muito maior que as demais.

A utilização do FKE, uma instância do filtro para cada alvo, em conjunto com o JPDA para rastreamento de múltiplos alvos segue o ciclo básico do FKE, tendo alterações apenas na fase de atualização. Sendo $n_t > 0$ o número de alvos sendo rastreados, denota-se por x_k^t o estado atual do alvo $t \leq n_t$ e P_k^t sua covariância.

Encontrar todas as associações possíveis entre todos os alvos, em termos de processamento, seria extremamente custoso (Liebens et al., 2006). Assim, apenas as associações que são mais prováveis de ocorrer são consideradas. Um modo de saber se uma associação tem boa probabilidade de ocorrer é comparar a distância entre a observação e o estado predito pelo alvo. Um método comum de medição de distância é a distância de *Mahalanobis*, assim apenas são validadas associações que satisfaçam a seguinte propriedade: $\sqrt{(\hat{z}_j^t)^T S_{k+1}^{-1} \hat{z}_j^t} \leq \gamma$, sendo \hat{z}_j^t a inovação correspondente da observação j em relação a predição do alvo t , S_{k+1} a covariância da inovação correspondente e γ um limiar passado como entrada (Liebens et al., 2006).

Para calcular a inovação \hat{z}^t resultante de cada um dos alvos, deve-se realizar o somatório de todas as inovações relativas a este, ponderados com suas respectivas probabilidades. Assim, tem-se $\hat{z}^t = \sum_{j=1}^u \beta_j^t \hat{z}_j^t$, onde β_j^t é a **probabilidade de associação** de que a observação j pertença ao alvo t e $u > 0$ é o número de observações. Para se calcular β_j^t , é necessário encontrar todos os eventos prováveis $\chi = \bigcap_{j=1}^m \chi_j^t$, onde χ_j^t é um evento em que a observação j foi associada a t . Os eventos prováveis são os conjuntos de eventos em que apenas um alvo é associado a uma observação e vice-versa, além disso apenas eventos que envolvam associações válidas são computados (Roeker and Phillis, 1993).

Na Figura 2, supondo que a, b, c sejam predições (as elipses são as áreas de validação) e que 1, 2, 3, 4 e 5 sejam observações, um evento provável é o conjunto de associações $\chi(k) = \{(a, 2), (b, 4), (c, 3)\}$ e um evento não-provável é $\{(a, 1), (b, 3), (c, 2)\}$, pois a observação 1 não se encontra na área de validação de a .

A probabilidade do evento provável χ condicionado em todas as observações no intervalo de tempo k é denotada por $Pr(\chi | Y_k)$ (Fortmann et al., 1983). Depois de se obter todos os eventos prováveis χ e suas probabilidades, a probabilidade de associação β_j^t é a probabilidade do evento onde a observação j é associada ao alvo t , condicionado

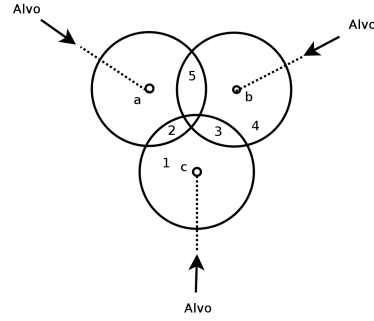


Figura 2: Áreas de validação.

em todas as observações no intervalo de tempo k (Liebens et al., 2006):

$$\beta_j^t = \sum_{\chi} Pr(\chi | Y_k) \omega_{jt}(\chi), \quad (11)$$

onde $\omega_{jt}(\chi)$ é igual a 1 se no evento χ a observação j foi associada ao alvo t . Obtendo β_j^t para cada alvo em relação a cada observação, pode-se calcular a inovação combinada \hat{z}^t dada anteriormente.

Finalmente, para cada alvo tem-se qual a inovação deste em relação a sua respectiva observação abstrata atribuída. Como utilizou-se uma inovação combinada para atualização da predição \hat{x}_{k+1} , também deve-se utilizar um ganho de Kalman combinado G^t para cada alvo t , calculado de maneira análoga:

$$G^t = \sum_{j=1}^u \beta_j^t G_j^t. \quad (12)$$

A atualização da covariância é alterada pois agora existe a possibilidade do alvo não ter sido detectado no espaço de busca, e é dada por (Fortmann et al., 1983):

$$P_{k+1}^t = \hat{P}_{k+1}^t - (1 - \beta_0^t) G^t S_{k+1}^t (G^t)^T + P U_{k+1}^t, \quad (13)$$

$$P U_k^t = G^t \left[\left(\sum_{j=1}^u \beta_j^t \hat{z}_j^t (\hat{z}_j^t)^T \right) - \hat{z}^t (\hat{z}^t)^T \right] (G^t)^T, \quad (14)$$

onde $P U_k^t$ é relatado como a incerteza da origem da observação.

Fazendo a atualização do estado atual e da covariância, está concluída uma iteração do FKE integrado ao JPDA, sendo que para cada iteração seguinte, todo o processo é repetido novamente.

Em (Liebens et al., 2006) é aplicada exatamente a mesma técnica de rastreamento e associação de dados que a utilizada neste trabalho, o Filtro de Kalman e o JPDA, porém sua aplicação é para o rastreamento de pessoas. Além disto, como é muito comum haver oclusão de parte dos alvos, é utilizado um modelo de pessoa para reconhecer os casos de oclusão e tratá-los.

3 Resultados Obtidos

Foram realizados dois tipos de testes, um deles foi feito sob ambiente simulado, ou seja, houve uma escolha dos valores de posição inicial e das observações em cada imagem. O outro teste foi realizado utilizando um vídeo real como entrada, assim cada quadro do vídeo fornece as observações das larvas contidas no plano da imagem, sendo que o estado inicial das larvas é dado por suas posições no primeiro quadro. O espaço de observação considerado tem tamanho de 720×480 pixels.

O primeiro teste simulado consiste em rastrear 2 larvas, com posições iniciais distantes uma da outra, cujas trajetórias são paralelas, conforme mostrado na Figura 3(a). Foram realizados 5 testes com 10 iterações do filtro para cada um. O erro durante cada quadro é mostrado na Figura 3(b), considerando como erro a distância em pixels entre a posição real da larva e a posição obtida pelo filtro. No gráfico, o eixo x corresponde a quantidade de quadros e o eixo y corresponde a média dos erros de posição dos alvos para os 5 testes.

O segundo teste simulado consiste em rastrear 2 larvas, com posições iniciais distantes uma da outra, porém suas trajetórias são cruzadas, de modo que em um determinado intervalo de tempo ocorre contato entre as larvas, conforme mostrado na Figura 4(a). Foram realizados 5 testes com 10 iterações do filtro para cada um. O erro durante cada quadro é mostrado na Figura 4(b).

O terceiro teste simulado consiste em rastrear 10 larvas, com posições iniciais e trajetórias aleatórias. O trajeto gerado pode ser visto na Figura 5(a). Foram realizados 5 testes com 10 iterações do filtro para cada um. Os erros obtidos são dados pelo gráfico contido na Figura 5(b).

Para os testes simulados realizados, pode-se ver pelas Figuras 3(b), 4(b) e 5(b) que o sistema responde de uma forma bastante uniforme devido a um controle maior sobre as entradas. Considerando o teste simulado com 2 larvas da Figura 4(b), dos quadros 3 a 6 começa ocorrer contato entre as larvas o que ocasiona um ligeiro aumento do erro, já dos quadros 7 a 10 ocorre uma diminuição do erro. Para o teste simulado contendo 10 larvas, pode-se ver que o erro é baixo, no máximo 3 pixels, porém maior em relação àqueles testes com 2 larvas, de 2 pixels, devido a imperfeição do modelo de movimento, mas ainda assim o resultado é bastante satisfatório.

Para o teste real, utilizou-se uma câmera instalada em uma posição acima do plano contendo o experimento e apontada para o centro do pote, conforme mostrado na Figura 1(b). O teste foi feito utilizando uma filmagem de aproximadamente 10 segundos, com 5 quadros por segundo e de resolução 720×480 pixels. Cada imagem é segmentada, extraindo as regiões de interesse, ou seja, as regiões em que se situam as larvas, sendo

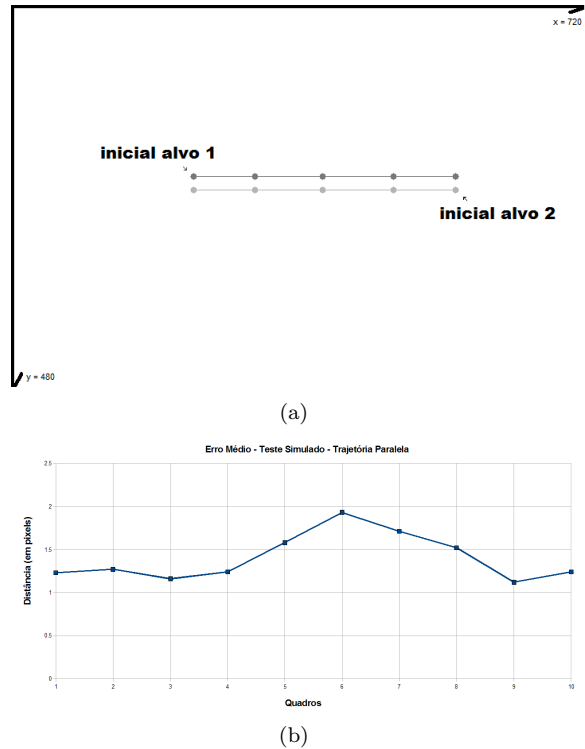


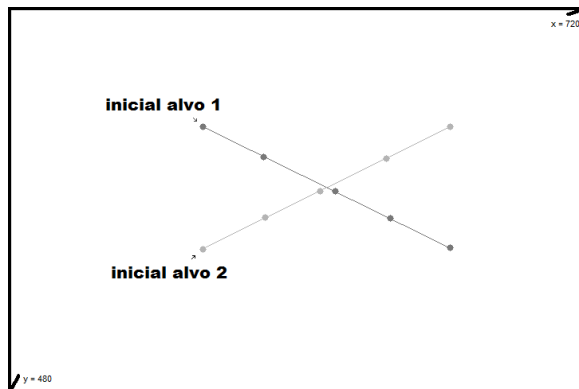
Figura 3: (a) Dois alvos com trajetórias em paralelo. (b) Erro do teste simulado - Trajetórias em paralelo.

o centróide de cada larva utilizado como observação para o FKE. A Figura 6 mostra o gráfico de erros para o teste real. Nas iterações iniciais nota-se um erro bastante pequeno, porém à partir do quadro 4 ocorre bastante contato entre as larvas o que resulta num aumento do erro obtido. Apesar da oscilação dos valores de erros, devido a imperfeição do modelo de movimento, consegue-se uma média de 2,5 à 3 pixels de erro ao longo do restante do experimento.


Considerando os experimentos com testes simulados e reais, como o espaço de observação é bastante grande (720×480 pixels), tem-se que o erro médio obtido é praticamente desprezível, além disto não houve perda do rastreamento para nenhum alvo em cada um dos testes. Entretanto, para se obter estes resultados é necessário que a segmentação da imagem forneça o centróide de cada larva existente na imagem, ou seja, o número de observações obtidas em uma imagem deve ser no mínimo igual ao número de larvas sendo rastreadas. Desta forma, tomando como base os resultados obtidos, conclui-se que a técnica de FKE em conjunto com JPDA para rastreamento de múltiplas alvos, é bastante satisfatória no rastreamento de larvas do mosquito *Aedes Aegypti*.

4 Conclusão e Trabalhos Futuros

A aplicação do FKE em conjunto com o JPDA para rastreamento de múltiplos alvos, mostrou-



(a)



(b)

Figura 4: (a) Dois alvos com trajetórias em cruz. (b) Erro do teste simulado - Trajetórias em cruz.

se viável no rastreamento de larvas do mosquito *Aedes Aegypti*, como pode ser comprovado pelos diversos experimentos realizados. Os resultados mostraram que nenhum dos alvos foi perdido, além de obter erros de estimação de posição bastante baixos, o que torna promissora a aplicação desta em muitos outros casos de rastreamento.

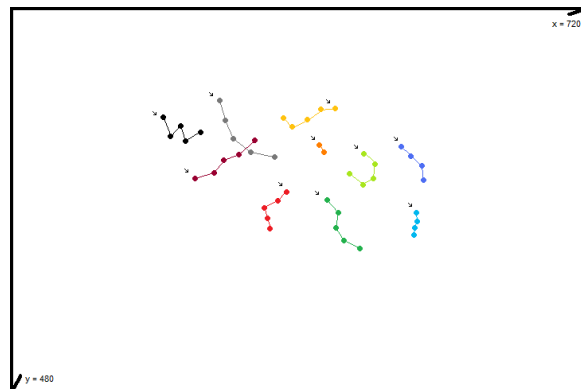
Como parte dos trabalhos futuros está previsto realizar mais experimentos com dados reais, ou seja, outros vídeos das larvas. Também faz parte dos próximos passos, testar a técnica em outros domínios de aplicação, como outros tipos de larvas, bem como em animais maiores como camundongos.

Agradecimentos


Esta pesquisa foi desenvolvida sob o projeto LARVIC, recebendo apoio da FUNDECT - Fundação de Apoio ao Desenvolvimento do Ensino, Ciência e Tecnologia do Estado de Mato Grosso do Sul. Os autores também são imensamente gratos a empresa TecSinapse por todo o apoio concedido.

Referências

Cuevas, E., Zaldivar, D. and Rojas, R. (2005). Kalman filter for vision tracking, *Technical Report B05-12*, Freie Universität Berlin, Institut für Informatik, Berlin.



(a)



(b)

Figura 5: (a) Dez alvos com trajetórias aleatórias. (b) Erro do teste simulado - Trajetórias aleatórias.




Figura 6: Erro do teste real - 10 larvas.

Fortmann, T., Bar-Shalom, Y. and Scheffé, M. (1980). Multi-target tracking using joint probabilistic data association, *19th IEEE Conference on Decision and Control including the Symposium on Adaptive Processes*, Vol. 19, pp. 807–812.

Fortmann, T., Bar-Shalom, Y. and Scheffé, M. (1983). Sonar tracking of multiple targets using joint probabilistic data association, *IEEE Journal of Oceanic engineering* 8(3): 173–184.

Gonçalves, W. N., Monteiro, J. B. O., de Andrade Silva, J., Machado, B. B., Pistori, H. and Odakura, V. (2007). Multiple mice tracking using a combination of particle filter and k-means, *SIBGRAP '07, XX Brazilian Symposium on Computer Graphics and Image Processing*, IEEE Computer Society, Los Alamitos, CA, USA, pp. 173–178.

- Kalandros, M. and Pao, L. (2001). Sensor management for tracking interacting targets, *Workshop on Estimation, Tracking, Fusion and Control: A Tribute to Yaakov Bar-Shalom*, Monterey, CA, pp. 221–248.
- Kalman, R. E. (1960). A new approach to linear filtering and prediction problems, *Journal of Basic Engineering* .
- Kirubarajan, T. and Bar-Shalom, Y. (2004). Probabilistic data association techniques for target tracking in clutter, *Proceedings of the IEEE* **92**(3): 536–557.
- Liebens, M., Sakiyama, T. and Miura, J. (2006). Visual tracking of multiple persons in a heavy occluded space using person model and joint probabilistic data association, *IEEE International Conference Multisensor Fusion and Integration for Intelligent Systems* pp. 547–552.
- Maybeck, P. S. (1979). *Stochastic models, estimation and control*, Vol. 1, Academic Press.
- Roecker, J. and Phillis, G. (1993). Suboptimal joint probabilistic data association, *IEEE Transactions on Aerospace and Electronic Systems* **29**(2): 510–517.