

Hiroito Watanabe

**Rastreamento de objeto
e estimativa de movimento**

Brasil

2015

Hiroito Watanabe

Rastreamento de objeto e estimativa de movimento

Relatório do trabalho 2 da disciplina de Processamento Digital de Sinais II, ministrada pelo Prof. Dr. Eduardo Ribeiro.

Universidade do Federal do Paraná – UFPR

Departamento de Engenharia Elétrica

Curso de Engenharia Elétrica

Brasil

2015

Resumo

O filtro Kalman é utilizado de várias formas, e uma delas é no rastreamento e estimativa de objetos em situações de muito ruído e interferências, como por exemplo posicionamento de aeronaves baseado em medidas de GPS ou estimativa de posição de objeto em vídeo.

Palavras-chaves: Kalman. Visão computacional.

Lista de ilustrações

Figura 1 – Subtração de plano de fundo.	12
Figura 2 – Detecção de blob.	12
Figura 3 – Algoritmo do filtro Kalman.	13
Figura 4 – Detecções sem filtro.	15
Figura 5 – Detecções com filtro Kalman.	16
Figura 6 – Detecção sem filtro.	17
Figura 7 – Modelo de aceleração constante do filtro Kalman.	18
Figura 8 – Modelo de velocidade constante do filtro Kalman.	19
Figura 9 – Detecção sem filtro.	20
Figura 10 – Modelo de aceleração constante do filtro Kalman.	21

Sumário

	Introdução	7
1	OBJETIVO	9
2	DESENVOLVIMENTO	11
2.1	Subtração do plano de fundo	11
2.2	Detecção de blob	12
2.3	Filtro Kalman	13
3	RESULTADOS	15
3.1	Caso 1	15
3.2	Caso 2	16
3.3	Caso 3	17
	Conclusão	23
	REFERÊNCIAS	25

Introdução

Na área de visão computacional, o rastreamento de objetos em movimento é muito utilizado pois permite um monitoramento constante sem supervisão de um operador. Esta ferramenta é útil para edição de vídeo, comunicação em vídeo, segurança e monitoramento, entre outras áreas.

Este trabalho foi desenvolvido no software Matlab a partir de um algoritmo apresentado no site da Mathworks ([MATHWORKS](#), b).

1 Objetivo

O trabalho foi desenvolvido com foco no aprendizado e utilização do filtro Kalman da *toolbox* de visão computacional do *Matlab* ([MATHWORKS, a](#)). Através de vídeos capturados pelo autor e modificados para simular situações diversas.

O parâmetros do filtro são uma ciência a parte, e portanto não foi estudado nenhum método de ajuste de parâmetros, para os casos estudados, o filtro foi ajustado empiricamente proporcionando assim um melhor entendimento de como o desempenho é afetado por cada ajuste.

Neste trabalho o filtro foi utilizado para a detecção de somente um objeto em movimento e com a câmera estática durante todo o vídeo.

2 Desenvolvimento

Os vídeos são analisados quadro a quadro, o processamento é feito em basicamente três etapas, porém neste trabalho o foco foi na última etapa, de utilização do filtro Kalman (WELCH, 2001).

2.1 Subtração do plano de fundo

O primeiro passo para a detecção do objeto em movimento no vídeo é analisar os quadros iniciais quando objeto a ser rastreado ainda não entrou em quadro. Este quadro inicial será utilizado para subtrair o plano de fundo dos quadros seguintes. Como a única diferença entre os primeiros quadros e o resto do vídeo é o objeto em movimento, a imagem resultante é muito relacionada ao objeto.

Esta operação é possível pois há somente um objeto em movimento durante todo o vídeo, portanto não há possibilidade de confusão com outros objetos em movimento.

Com o vídeo capturado em cores, primeiramente foi necessário transformar as imagens em escala de cinza, para que as três matrizes RGB fossem simplificadas em apenas uma matriz de tons de cinza. A subtração de plano de fundo foi então aplicada sobre estas imagens. Os valores obtidos ao final desta subtração são proporcionais a diferença entre as imagens, e este resultado pode conter interferências de ruídos ou mesmo da qualidade da imagem. Para isso a imagem passa por uma espécie de filtro binário, que separa todos os *pixels* da imagem para zero ou um, e este limite de separação é arbitrário chamado de *threshold*.

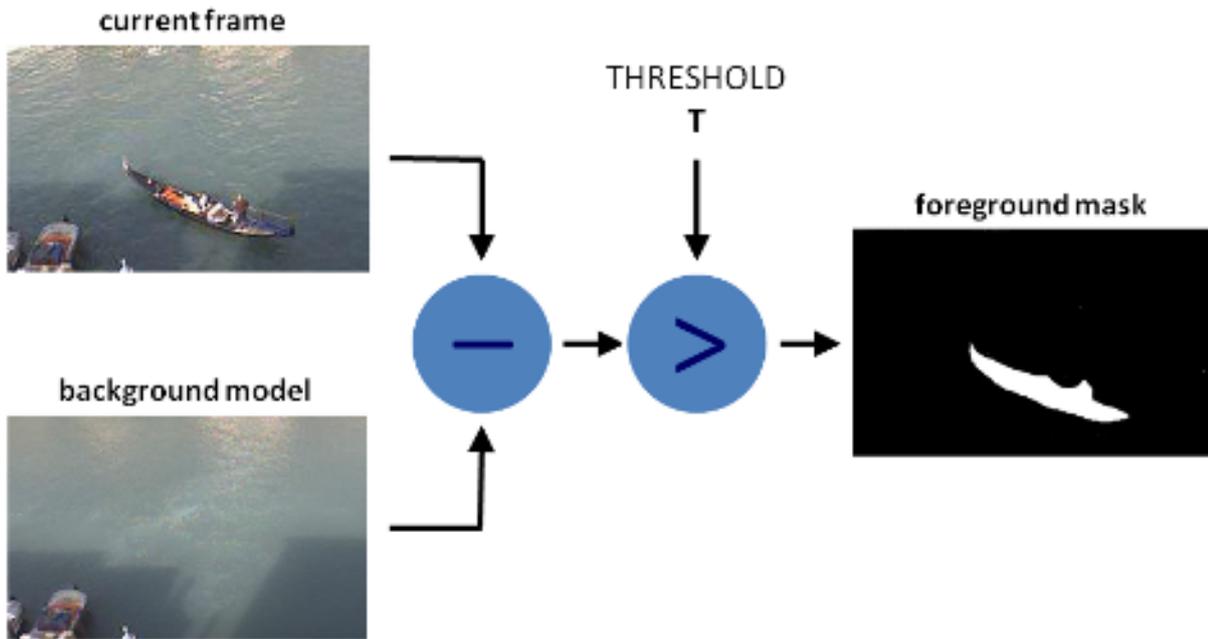


Figura 1: Subtração de plano de fundo.



Figura 2: Detecção de blob.

2.2 Detecção de blob

Após a subtração do plano de fundo, o algoritmo faz a detecção de blob, onde basicamente o computador identifica um grupo de *pixels* similares em cor ou intensidade e os agrupa em uma bolha.

Este método permite que o computador encontre a posição da bolha em cada quadro e identifique o movimento do objeto. Esta técnica aliada a etapa anterior garantem uma boa detecção do objeto quando a imagem possui relativamente baixo ruído e quando o objeto aparece no quadro.

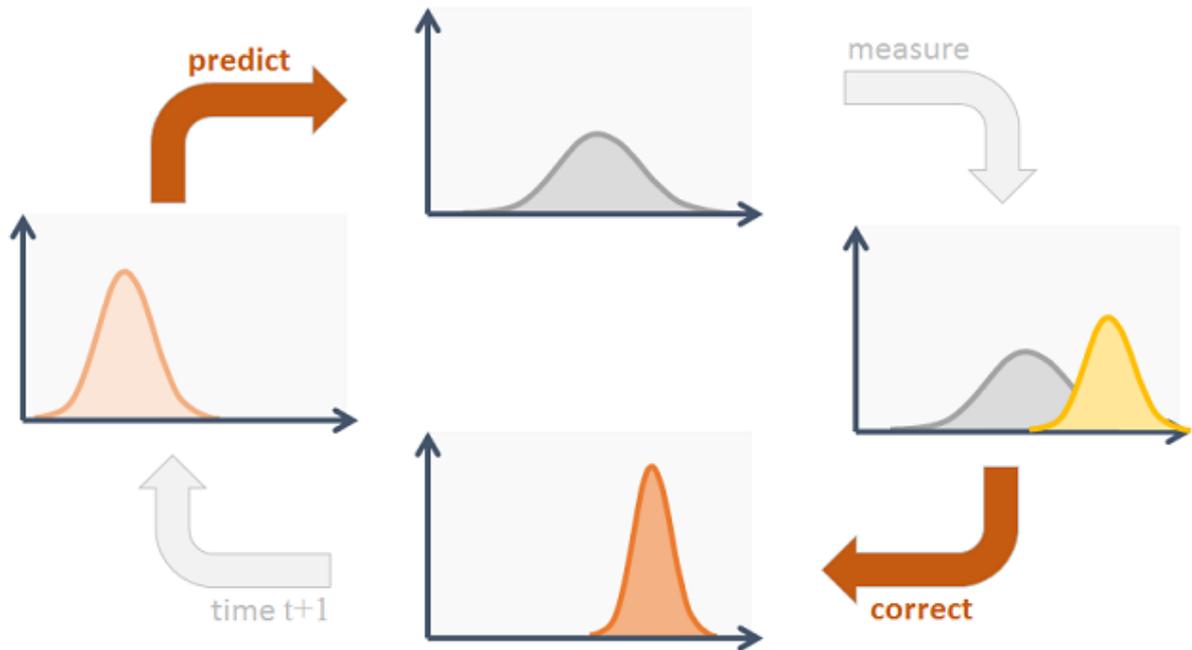


Figura 3: Algoritmo do filtro Kalman.

2.3 Filtro Kalman

O filtro Kalman funciona estimando o estado do sistema a partir do estado no momento anterior. O resultado da medição do sistema é então ponderado e o sistema é atualizado, sendo que o resultado é um valor intermediário entre a estimativa e a medição.

Todas as variáveis são assumidas como uma distribuição gaussiana, esta é uma característica do filtro que pode afetar o desempenho pois não são todos os processos que se comportam como uma distribuição gaussiana. Porém este filtro pode ser utilizado em muitos outros casos por terem esta mesma característica.

Os modelos de sistema utilizados neste trabalho são da *toolbox* de visão computacional do *Matlab*. Os modelos são de objeto com aceleração constante, ou velocidade constante. Cada modelo tem seus respectivos parâmetros a serem alterados de forma a ajustar o modelo ideal ao modelo real.

Além dos parâmetros de posição, velocidade e aceleração de cada modelo, também é possível alterar o parâmetro do erro, desta forma o modelo pode depender mais das medidas realizadas ou do estado do sistema.

Os parâmetros são então formatados em matrizes de covariância e atualizam o sistema a cada nova medidas, sendo que não é necessário conhecer todos os momento anteriores ao atual, somente o anterior imediato que já contém o histórico do modelo. Para uma introdução intuitiva e matemática ao filtro Kalman, ver (FARAGHER, 2012).

3 Resultados

Três casos foram analisados neste trabalho.

3.1 Caso 1

O primeiro caso da figura 4 uma bola de bilhar branca atravessa a mesa azul com uma barreira no meio. As detecções estão marcadas em preto e neste caso o filtro de Kalman ainda não foi aplicado, portanto quando a bola está atrás da barreira o sistema desconhece a localização da bola e não consegue estimar a posição ou movimento. Vale observar que a barreira usada na filmagem causava muito problema em relação a detecção ao longo do vídeo, por isso digitalmente foi adicionada uma barreira preta uniforme através do software Sony Movie Studio.

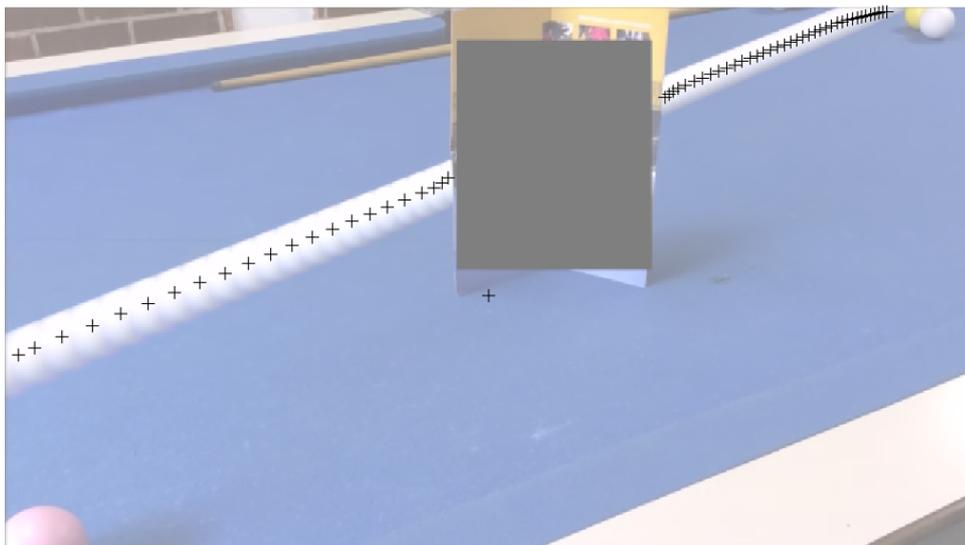


Figura 4: Detecções sem filtro.

Quando o filtro é aplicado e os parâmetros são ajustados corretamente, é possível estimar o estado do sistema quando o objeto não pode ser detectado. É possível ver na figura 5 os

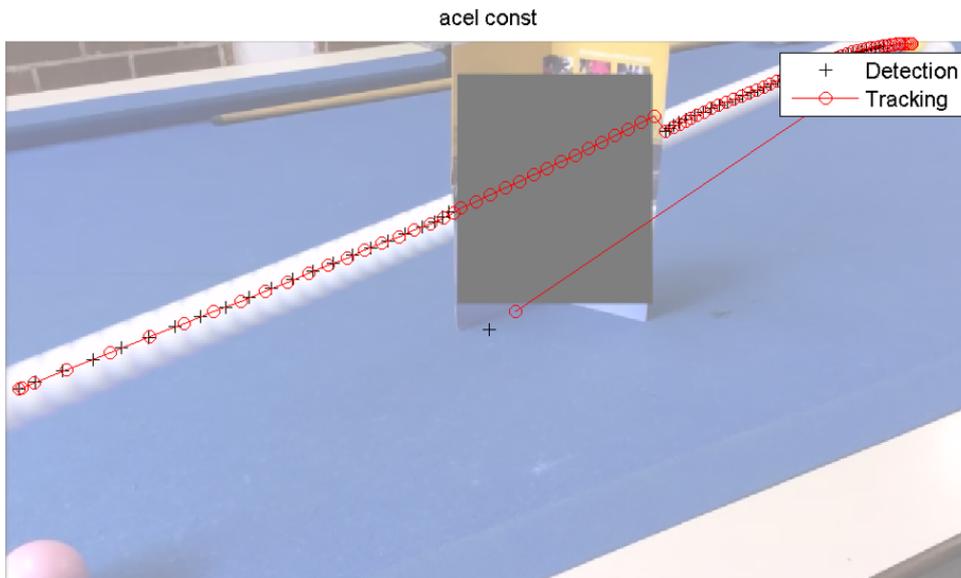


Figura 5: Detecções com filtro Kalman.

pontos em vermelho que indicam a posição do objeto segundo o filtro. O modelo de aceleração constante foi utilizado pois é possível observar na imagem que há uma grande desaceleração devido ao atrito, entre o começo do vídeo e o fim do vídeo.

Mesmo com os parâmetro ajustados é possível perceber que após muitos quadros o filtro perde a precisão pois não há medições para atualizar o estado do sistema. de qualquer forma é importante notar que o estado estimado é muito próximo do estado real do sistema e este modelo ainda pode ser melhorado com a sintonização dos parâmetros.

3.2 Caso 2

Este caso é muito parecido com o caso 1, porém a barreira aqui utilizada possui cor uniforme e a iluminação relativamente uniforme durante toda a duração do vídeo.

Como pode ser observado na figura 6 a bola branca se move rapidamente e quase não sofre o efeito do atrito da mesa, o deslocamento da posição da bola entre quadros no começo e no fim do vídeo é praticamente igual, isso permite utilizar o modelo de aceleração constante e velocidade constante para estimar a posição da bola atrás da barreira.

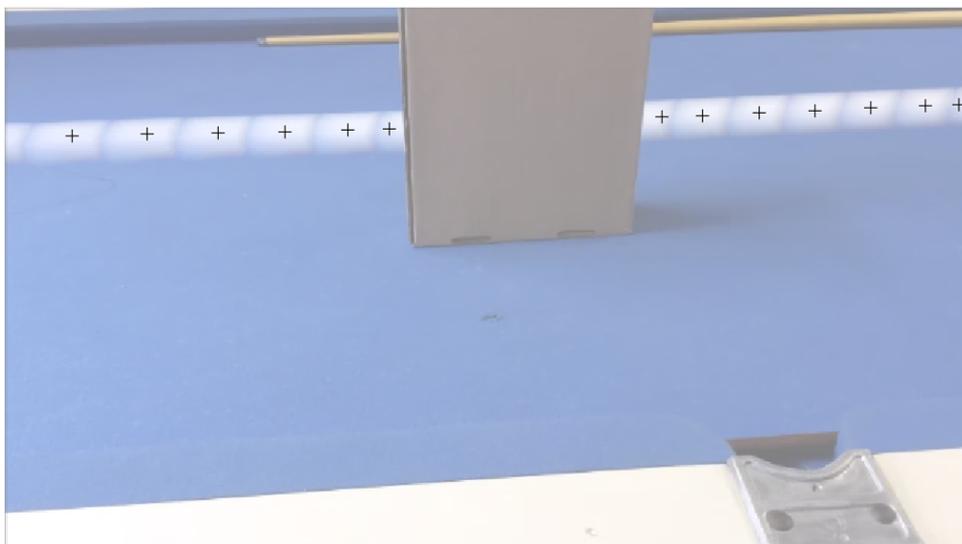


Figura 6: Detecção sem filtro.

Na figura 7 pode-se observar a trajetória estimada pelo filtro em vermelho, utilizando o modelo de aceleração constante. Nota-se um pequeno erro ao final da barreira, mas quando o vídeo é reproduzido com a sobreposição do filtro, é quase imperceptível este desvio.

O modelo de velocidade constante também foi possível ajustar neste caso pois a bola se move muito rápido durante todos os quadros e o atrito se torna desprezível. Na figura 8 a trajetória do filtro é quase igual da figura 7.

3.3 Caso 3

Neste último caso as condições foram alteradas significativamente. A bola não mais atravessa a mesa em linha reta, agora ela faz um zigzag nas bordas da mesa até sair do enquadramento. Cada vez que a bola muda de direção o sistema muda drasticamente. É possível notar também uma grande diferença na velocidade da bola no início do vídeo e no fim causado pelo trajeto com obstruções e o atrito da mesa.

Neste vídeo não foi colocada barreira nem física nem digital nas imagens, porém para simular a barreira, o algoritmo de detecção foi desligado por alguns quadros enquanto o filtro permanecia ligado.

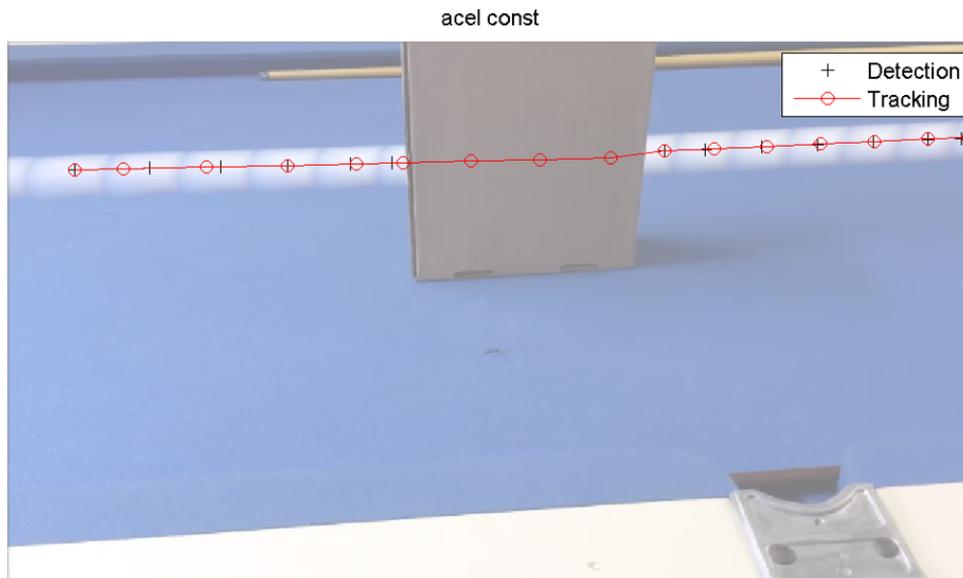


Figura 7: Modelo de aceleração constante do filtro Kalman.

Para testar a robustez do filtro, foi também adicionado ruído gaussiano as imagens. É possível perceber na figura 9 que há ruído e que as detecções não foram feitas em parte dos quadros.

Nas bordas da mesa onde a bola muda rapidamente de direção é possível notar a resposta do filtro que se ajusta as novas medidas realizadas após a colisão, portanto perde-se a precisão de algumas medidas neste caso, mas este filtro permite que durante a falta de detecção a posição possa ser estimada como mostra a figura 10. O ruído também não teve muita influência na resposta do filtro, que teve o estado do sistema alterado mais pelas mudanças de direção.

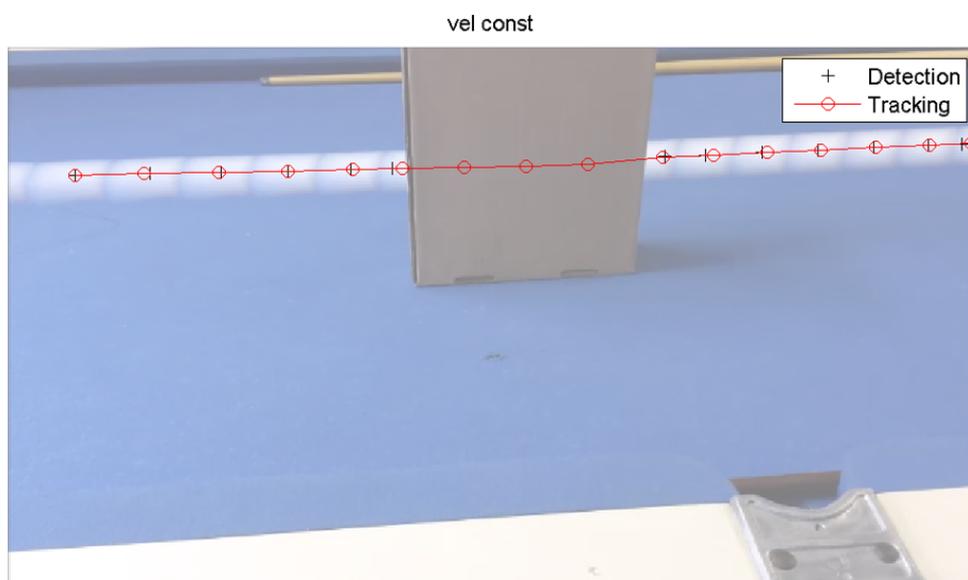


Figura 8: Modelo de velocidade constante do filtro Kalman.

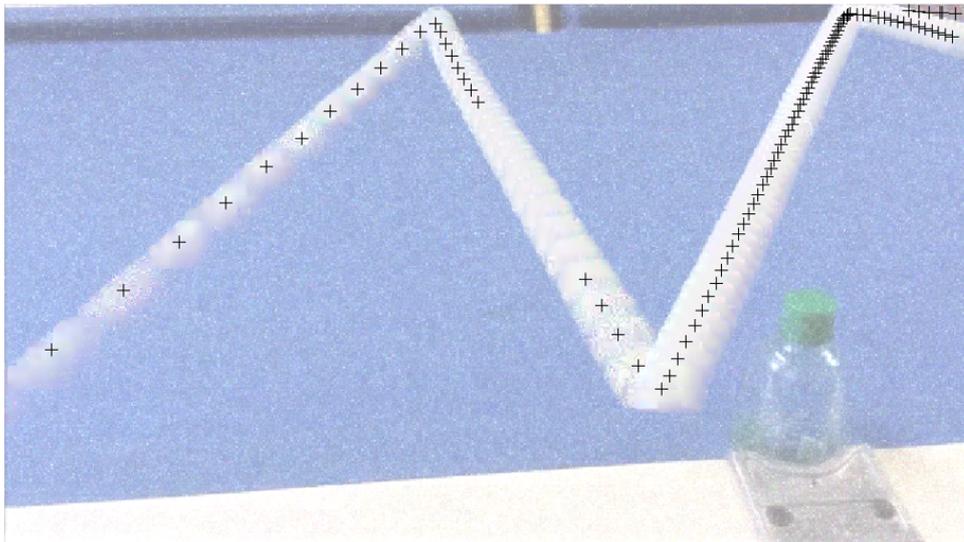


Figura 9: Detecção sem filtro.

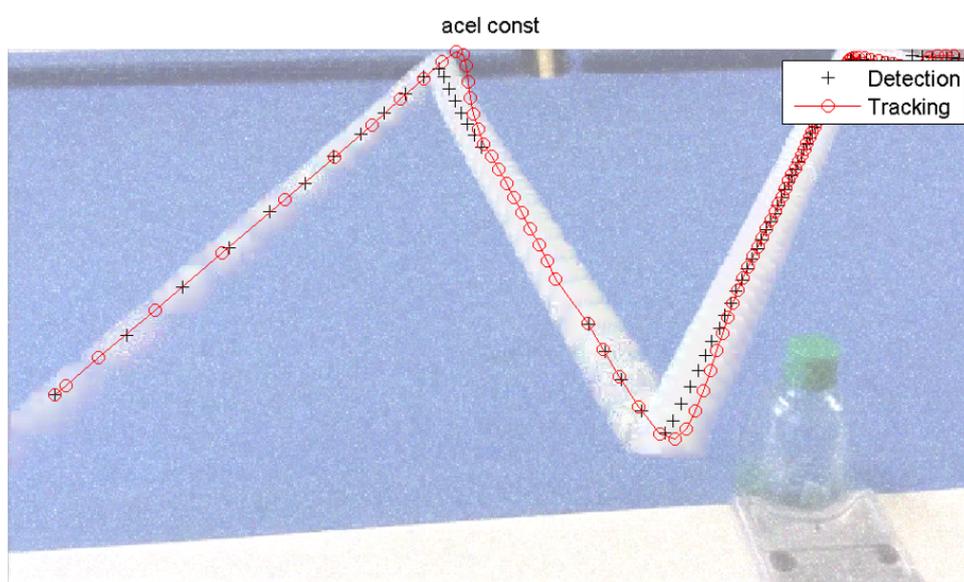


Figura 10: Modelo de aceleração constante do filtro Kalman.

Conclusão

O filtro Kalman se mostrou muito bom para os problemas propostos, onde a maior dificuldade foi o ajuste dos parâmetros do filtro.

Para um melhor desempenho algum método de ajuste otimizado poderia ser utilizado, fazendo assim uso do máximo potencial do filtro.

Este filtro poderia ser utilizado para aplicações mais complexas como rastreamento de múltiplos objetos ([MATHWORKS, c](#)), sistemas não lineares com o uso do filtro de Kalman estendido e outras áreas além da visão computacional.

Referências

FARAGHER, R. *Understanding the Basis of the Kalman Filter Via a Simple and Intuitive Derivation*. 2012. Disponível em: <www.cl.cam.ac.uk/~rmf25/papers/Understanding%20the%20Basis%20of%20the%20Kalman%20Filter.pdf>. Citado na página 13.

MATHWORKS. *Computer Vision System Toolbox*. Disponível em: <www.mathworks.com/products/computer-vision>. Citado na página 9.

MATHWORKS. *Design and use Kalman filters in MATLAB and Simulink*. Disponível em: <www.mathworks.com/discovery/kalman-filter.html>. Citado na página 7.

MATHWORKS. *Motion-Based Multiple Object Tracking*. Disponível em: <www.mathworks.com/help/vision/examples/motion-based-multiple-object-tracking.html>. Citado na página 23.

WELCH, G. B. G. *An Introduction to the Kalman Filter*. 2001. Disponível em: <www.cs.unc.edu/~tracker/media/pdf/SIGGRAPH2001_CoursePack_08.pdf>. Citado na página 11.