

Detecção de Eventos em Multidão

Felipe Mathias Schmidt ¹, Claudio Rosito Jung ²



UFRGS
PROPEAQ
CET - Ciências Exatas e da Terra

XXV SIC
Salão Iniciação Científica

1 Autor: Felipe Mathias Schmidt, Ciência da Computação, UFRGS
2 Orientador: Claudio Rosito Jung, Instituto de Informática UFRGS
Temática: Informática - COMPUTAÇÃO GRÁFICA, REALIDADE VIRTUAL E PROCESSAMENTO DE IMAGENS

MOTIVAÇÃO

Detectar e analisar imagens de movimento de multidões, fazendo uso de fluxo ótico (*optical flow*) [1]. Com os vetores de movimento resultantes deste fluxo, podemos usar algoritmos de clusterização para identificação dos grupos presentes na imagem, agrupando assim vetores de movimento em uma massa denominada *cluster*.

OBTENDO CLUSTERS

Nossa intenção é usar as informações de agrupamento geradas para identificar um conjunto pessoas (representadas por vetores), as quais tenham um padrão de movimento semelhante; este caso se torna bastante interessante quando temos mais de um grupo de pessoas em movimento, como mostrado nas imagens abaixo:

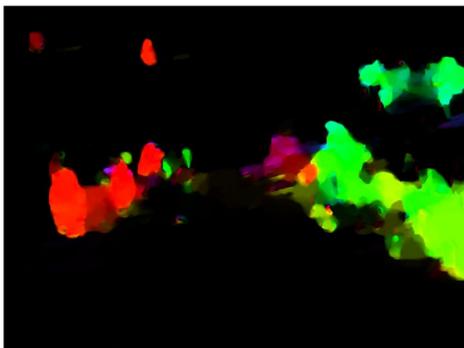


(Evento em Crowd 1)



(Evento em Crowd 2)

Usando estas imagens como entrada para nosso algoritmo, geramos vetores de movimento que podem ser representados como a seguir:



(Vetores de Movimento)

Com uma sequência de imagens podemos também estimar o *background* e o *foreground*; isto nos ajuda a descartar vetores pertencentes ao fundo que prejudicam na clusterização. Para esta estimativa estamos usando [2].

Nesta etapa temos massas de vetores que mostram a direção do movimento dos grupos da imagem; como eles tem sentido de movimento oposto neste exemplo, idealmente os vetores de cada grupo refletirão este comportamento, sendo assim, basta clusterizar (agrupar) os vetores de valores semelhantes. A imagem abaixo é uma representação dos clusters com uso de k-means para obtenção dos mesmos, usando $k = 3$ clusters.



(Clusteres Gerados)

Em vários casos é difícil se obter um resultado como o esperado; a fim de melhorá-los, podemos usar outras métricas de similaridade entre os vetores, como por exemplo, adicionar a localização espacial dos vetores. Também se pretende estudar outros algoritmos de clusterização, em particular aqueles que estimam o número de clusters de forma automática.

DIFICULDADES

As maiores dificuldades encontradas neste trabalho tangem principalmente a parte de clusterização dos vetores de movimento. Os dois pontos mais relevantes são:

- 1 – Automatização da definição do número de clusters;
- 2 – Evitar que vetores sejam atribuídos à um cluster errado;

No presente momento, os esforços maiores estão sendo aplicados para a solução do segundo ponto citado.

REFERÊNCIAS

- [1] T. Brox, J. Malik. Large displacement optical flow: descriptor matching in variational motion estimation, IEEE Transactions on Pattern Analysis and Machine Intelligence, 33(3):500-513, March 2011.
- [2] Jung, C. R. Efficient background subtraction and shadow removal for monochromatic video sequences. IEEE Transactions on Multimedia 11(3):571-577, 2009