

Um algoritmo para identificar padrões comportamentais do tipo *avoidance* em trajetórias de objetos móveis

Alisson Moscato Loy¹, Vania Bogorny², Chiara Renso³, Luis Otavio Alvares¹

¹II – Universidade Federal do Rio Grande do Sul, Porto Alegre, Brasil
{amloy, alvares}@inf.ufrgs.br

²INE – Universidade Federal de Santa Catarina, Florianópolis, Brasil
vania@inf.ufsc.br

³KDD Laboratory – ISTI CNR, Pisa, Italia
chiara.renso@isti.cnr.it

Resumo. *O foco do estudo de padrões comportamentais em trajetórias tem sido a busca por padrões de aglomeração ou semelhança no deslocamento de entidades no espaço e no tempo. Este artigo propõe um algoritmo para a detecção de um novo padrão comportamental que indica quando um objeto móvel está evitando determinadas regiões espaciais. Tal comportamento foi denominado neste artigo de avoidance. O algoritmo é avaliado através de experimentos com dados reais coletados na cidade de Porto Alegre.*

1. Introdução

O estudo de padrões comportamentais em trajetórias de objetos móveis está sendo desenvolvido principalmente sob duas óticas de pesquisa, a geométrica [Laube et al 2005, Gudmundsson e Kreveld 2006, Cao et al 2007, Giannotti et al 2007] e a semântica [Alvares et al 2007, Palma et al 2008, Bogorny et al 2009].

Dentro do estudo de comportamentos de trajetórias sob o ponto de vista geométrico, Laube [Laube et al. 2005] definiu um conjunto de padrões espaço-temporais baseados na direção do movimento e localização do objeto móvel, dentre os quais podemos citar: *flock* - representa um grupo de trajetórias de objetos móveis que se desloca de forma conjunta dentro de um dado raio no espaço; *leadership* - define um deslocamento com padrão de liderança, onde os seguidores devem estar dentro de uma determinada distância de tolerância; *convergence* - representa grupos de trajetórias que se encontram em uma determinada localização em uma dada janela temporal; e *encounter* - semelhante ao padrão *convergence*, porém as trajetórias devem estar juntas num dado raio no mesmo período de tempo. Este e outros trabalhos identificam padrões com base na variação da direção no tempo, e analisam grupos de trajetórias.

Observou-se, porém, a inexistência de estudos que procurem identificar o comportamento de objetos móveis que, ao se deslocar no espaço, evitam determinadas regiões ou evitam outras trajetórias como ocorre quando, por exemplo, pessoas evitam cruzar com determinadas pessoas enquanto caminham em um parque, veículos que mudam de rota frente a situações de tráfego lento ou ainda indivíduos que se deslocam em um ambiente de forma suspeita, evitando câmeras de vigilância ou postos de segurança.

Este artigo tem por objetivo propor um novo algoritmo, capaz de identificar este padrão comportamental *avoidance*, mais especificamente aquele que ocorre quando um objeto móvel evita determinada região espacial.

O artigo está organizado da seguinte forma: a seção 2 trata das heurísticas que norteiam a detecção da ocorrência do padrão comportamental *avoidance*. Na seção 3, um algoritmo construído com base nas heurísticas propostas é apresentado. Experimentos preliminares são apresentados na seção 4 e a conclusão na seção 5.

2. Heurísticas para detecção do padrão *avoidance*

O padrão comportamental *avoidance* ocorre, em termos gerais, quando um objeto móvel está se deslocando em direção a um objeto de interesse ou alvo, como uma câmera de vigilância, por exemplo, se desvia para evitar passar na região de alcance da câmera, e depois volta ao seu trajeto original. O problema é tentar diferenciar o que é realmente um desvio para evitar a câmera de uma mudança de rota por outro motivo qualquer.

Alguns aspectos a serem considerados são:

O objeto móvel deve estar indo em direção ao objeto alvo (o objeto a ser evitado) e se desviar do alvo relativamente perto deste para ser considerado um *avoidance*. Um contra-exemplo seria uma pessoa caminhando e que a um quilômetro de distância se desvia de uma câmera; ela provavelmente mudou de direção por outro motivo e não para escapar da câmera, não caracterizando então o comportamento *avoidance*.

O objeto móvel não deve cruzar (interceptar) a região do objeto alvo (a região de alcance da câmera, por exemplo), pois se o objeto muda de direção mas mesmo assim cruza a região coberta pela câmera, não a evitou, não caracterizando assim um *avoidance*.

A Figura 1 explicita estas idéias. A trajetória t_1 vinha em direção ao objeto alvo, se desvia e depois continua no rumo original, caracterizando um caso de *avoidance*. A trajetória t_2 vai em direção e intercepta o objeto alvo, não o evitando, não caracterizando por conseguinte, um caso de *avoidance*. Já a trajetória t_3 , vinha em direção ao objeto alvo mas se desvia deste muito longe (pelo fato do desvio ocorrer fora da *região de interesse* – caracterizada por uma distância d do objeto alvo), não caracterizando portanto o comportamento de *avoidance*.

Para reduzir a incidência de falsos positivos, que podem ocorrer em casos de mudanças de direção dentro da área de interesse ou imprecisão do aparelho de captura dos dados, exige-se que a porção da trajetória que vai na direção do objeto alvo dentro da região de interesse, denominada *subtrajetória direcionada ao alvo*, tenha um comprimento mínimo.

Um objeto móvel que evita a região coberta pela câmera e depois volta a seu trajeto original tem maior probabilidade de estar evitando a câmera do que um objeto que se desviou mas depois não retornou ao rumo anterior. A verificação deste comportamento é realizada testando-se a interseção da trajetória com uma região denominada *região de incremento de confiança*, que é definida como sendo uma região situada entre o objeto alvo e a borda da região de interesse no lado oposto à interseção da trajetória com a borda da região de interesse, e de largura igual ao objeto alvo. A região de incremento de confiança é única para cada trajetória considerada.




Figura 1. Exemplo de região de interesse, objeto alvo e comportamento de trajetórias.

Nos exemplos da Figura 2, a trajetória t1 possui uma subtrajetória direcionada ao alvo de tamanho válido e intercepta a região de incremento de confiança, apresentando um valor de confiança alto para a *avoidance*. A trajetória t2, da mesma forma, possui uma subtrajetória direcionada ao alvo válida, porém não intercepta a região de incremento de confiança, de modo que apresenta um valor fraco para confiança no *avoidance*. A trajetória t3 não apresenta uma subtrajetória direcionada ao alvo com tamanho válido e a trajetória t4 intercepta o objeto alvo, assim nenhuma destas duas trajetórias apresenta o comportamento *avoidance* em relação ao objeto alvo.

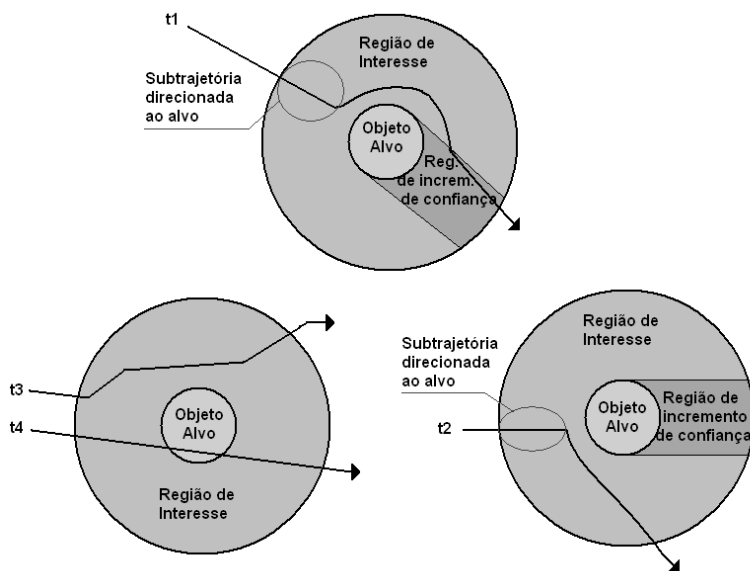


Figura 2. Exemplos de região de incremento de confiança e de subtrajetória direcionada ao alvo.

Uma última heurística utilizada é que a certeza de existir efetivamente um *avoidance* aumenta se o mesmo objeto móvel se desvia de vários objetos alvo.

3. Algoritmo para detecção de *avoidance*

Com base nas heurísticas definidas na seção 2, foi criado um algoritmo para detectar possíveis ocorrências do padrão comportamental *avoidance*, cujo pseudocódigo é apresentado na Figura 3 e explicado a seguir.

```

Entrada:  T // Conjunto de trajetórias
            O // Conjunto de objetos alvo
            d // tamanho do buffer da região de interesse em torno do objeto alvo
            subt // Tamanho mínimo da subtrajetória direcionada ao alvo

Saída:   Avt // Conjunto de graus de confiança de avoidance por trajetória

1. Início
2. Para  $t_i \in T$  | intersects ( $t_i$ , buffer(O, d)) faça // intercepta região de interesse
3.   Para  $o_k \in O$  faça
4.     Se intersects ( $t_i$ ,  $o_k$ ) // Testa interseção com objeto alvo
5.        $av_{ik} \leftarrow none$  // não é avoidance
6.     Senão
7.       Se Subtrajetoria( $t_i, o_k$ ) >= Subt
8.         RegIncr  $\leftarrow$  Calcula região de incremento de confiança
9.         Se intersects ( $t_i$ , RegIncr)
10.           $av_{ik} \leftarrow strong$  // avoidance forte
11.        Senão
12.           $av_{ik} \leftarrow weak$  // avoidance fraco
13.        Fim Se
14.      Senão
15.         $av_{ik} \leftarrow none$  // não é avoidance
16.      Fim Se
17.    Fim Para
18.  Fim Para
19.  Calcula Avti
20. Fim Para
21. Retorna Avt
22. Fim
    
```

Figura 3. Pseudocódigo do algoritmo para detecção de *avoidance*.

Se a trajetória intercepta a região de interesse então não tem *avoidance* (linhas 4 e 5). A função Subtrajetória (linha 7) retorna a maior subtrajetória que vai em direção ao alvo dentro da região de interesse e é detalhada no próximo parágrafo. Se a trajetória intercepta a região de incremento de confiança, então a confiança no *avoidance* é alta (linhas 9 e 10); caso contrário, a confiança no *avoidance* é mais baixa (linhas 11 e 12). O cálculo da confiança total do padrão *avoidance* de uma trajetória i é realizado na linha 19, utilizando a fórmula

$$Avt_i = \frac{\sum_{k=1}^n Av_{ik}}{n}$$

onde, n corresponde ao número de objetos alvo cuja região de interesse foi interceptada pela trajetória i , e Av_{ik} é a medida de *avoidance* da trajetória i em relação ao objeto alvo k e pode ter os valores 1 (*strong*), 0,5 (*weak*) e 0 (*none*).

A função Subtrajetória (linha 7) considera o primeiro ponto da trajetória dentro da região de interesse e vai pegando os próximos pontos, um a um, enquanto a direção da semireta que vai do ponto inicial ao ponto considerado intersecta o objeto alvo. Repete esta operação com os pontos seguintes, de forma a obter a maior subtrajetória em direção ao objeto alvo.

4. Experimentos preliminares

Para verificar a eficácia do algoritmo foram realizados experimentos preliminares com trajetórias obtidas a pé em uma praça e outras obtidas de carro em ruas e avenidas, todas na cidade de Porto Alegre. Estas trajetórias foram capturadas ora sem qualquer restrição, ora com a determinação de evitarem algumas regiões específicas, mapeadas como objetos alvo.

Para os experimentos de trajetórias de carro, foram coletadas 26 trajetórias e foram demarcadas seis regiões como objetos alvo, simulando locais de monitoramento por câmeras de segurança. Para este grupo de trajetórias, o experimento buscou identificar quais veículos apresentaram um padrão de comportamento do tipo *avoidance*, evitando as regiões monitoradas.

Levando-se em consideração que na região observada a largura máxima das avenidas é de aproximadamente 20m, usou-se esse valor como raio do objeto alvo. Já como buffer da região de interesse, utilizou-se 100m. O tamanho mínimo da subtrajetória direcionada ao alvo foi arbitrado em 8m.

O experimento resultou, como esperado, em seis ocorrências de *avoidance* detectadas, sendo cinco com valor *weak* para confiança local e uma com confiança local *strong*.

Na Figura 4 é possível visualizar parte das trajetórias 4, 17 e 22 e como elas se relacionam com o objeto alvo 3. Neste trecho, a trajetória 22 intercepta o objeto alvo não sendo, portanto, identificada como um possível *avoidance*. Já as trajetórias 4 e 17 apresentam o padrão comportamental procurado, pois evitam o objeto alvo. Nesta imagem também é possível visualizar a região de incremento de confiança gerada para a trajetória 4.

Os experimentos preliminares realizados com trajetórias de pedestres também tiveram bom resultado, tendo o algoritmo detectado corretamente os casos de *avoidance*. Este experimento não está detalhado por falta de espaço.

5. Conclusão

Este artigo apresenta um algoritmo para detecção de um novo padrão comportamental denominado *avoidance*, que ocorre quando objetos móveis evitam determinadas regiões espaciais. Para testar sua eficácia, foram realizados experimentos iniciais com dados reais obtidos com aparelhos GPS por veículos e por pessoas a pé. O algoritmo desenvolvido identificou com sucesso as trajetórias que evitaram as regiões estáticas informadas como objeto alvo, tanto nas trajetórias a pé quanto nas de carro, retornando o resultado esperado. Testes em maior escala estão sendo realizados para avaliar o comportamento e o desempenho do algoritmo com um volume de dados maior.




Figura 4. Visualização de parte das trajetórias obtidas de carro em relação ao objeto alvo 3.

6. Agradecimentos

Os autores agradecem ao CNPq (projeto 307588/2008-4), à FAPESC (CP005/2009), ao Projeto Europeu MODAP e ao CNR - Short Term Mobility Program, Itália, pelo financiamento parcial desta pesquisa.

Referências

- Alvares, L. O.; Bogorny, V.; Kuijpers, B.; Macedo, J. A. F.; Moelans, B.; Vaisman, A. (2007). A Model for Enriching Trajectories with Semantic Geographical Information.. In: Proc. of the ACM 15th International Symposium on Advances in Geographic Information Systems (ACM-GIS'07), Seattle, Washington, 7-9 November, p. 162-169.
- Bogorny, V.; Kuijpers, B.; Alvares, L.O. (2009). ST-DMQL: A Semantic Trajectory Data Mining Query Language. In: International Journal of Geographical Information Science. Taylor and Francis, p.1245-1276.
- Cao, H., Mamoulis, N., and Cheung, D. W. (2007). Discovery of periodic patterns in spatiotemporal sequences. IEEE Transactions on Knowledge and Data Engineering, 19(4):453–467.
- Giannotti, F., Nanni, M., Pinelli, F., and Pedreschi, D. (2007). Trajectory pattern mining. In Berkhin, P., Caruana, R., and Wu, X., editors, KDD, ACM, p. 330–339.
- Gudmundsson, J.; Kreveld, M. (2006). Computing longest duration flocks in trajectory data. In GIS'06: Proceedings of the 14th annual ACM international symposium on Advances in Geographic Information Systems, New York, NY, USA, ACM Press, p. 35–42,
- Laube, P., Kreveld, M., Imfeld, S. (2005). Finding remo - detecting relative motion patterns in geospatial lifelines. In Fisher, P.F., ed.: Developments in Spatial Data Handling. Proceedings of the 11th International Symposium on Spatial Data Handling. Springer, Berlin Heidelberg, p. 201–214.
- Palma, A. T; Bogorny, V.; Kuijpers, B.; Alvares, L.O. (2008). A Clustering-based Approach for Discovering Interesting Places in Trajectories. In: 23rd Annual Symposium on Applied Computing, (ACM-SAC'08), Fortaleza, Ceara, 16-20 March Brazil. pp. 863-868.