

# Um algoritmo para identificar padrões comportamentais tipo *avoidance*

Alisson Moscato Loy<sup>1</sup>, Vania Bogorny<sup>2</sup>, Chiara Renso<sup>3</sup>, Luis Otávio Alvares<sup>1</sup>

<sup>1</sup>Instituto de Informática – Universidade Federal do Rio Grande do Sul (UFRGS)  
Porto Alegre - RS

{amloy, alvares}@inf.ufrgs.br

<sup>2</sup>INE – Universidade Federal de Santa Catarina(UFSC)  
Florianópolis - SC

vania@inf.ufsc.br

<sup>3</sup>KDD 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 como avoidance. O algoritmo é avaliado através de experimentos com dados reais coletados na cidade de Porto Alegre.*

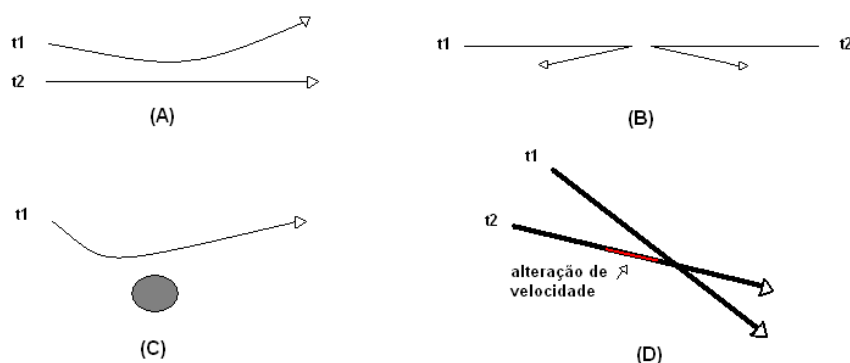
## 1. Introdução

O estudo de padrões comportamentais em trajetórias de objetos móveis está sendo desenvolvido principalmente sob duas óticas de pesquisa, a **semântica** [Alvares et al 2007, Bogorny et al. 2008, Palma 2008, Bogorny 2009, Manso 2010] e a **geométrica** [Laube 2002, Laube et al. 2005a, Laube et al. 2005b, Cao et al. 2007, Giannotti 2007, Benkert 2006].

Dentro do estudo de comportamentos de trajetórias sob o ponto de vista geométrico, Laube [Laube et al. 2004] definiu uma coleção 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.

Em 2006 Benkert [Benkert et al. 2006] estendeu a definição de *flock* para um conjunto de entidades movendo-se próximas uma das outras durante um intervalo de tempo. Também em [Gudmundsson et. al 2006] a noção de *flock* foi utilizada para identificar padrões de comportamento em trajetórias de longa duração. Estes trabalhos identificam padrões com base 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 comportamento, aqui denominado *avoidance*, pode ocorrer quando uma trajetória evita um objeto estático, quando duas ou mais trajetórias mudam de direção de modo a evitar a intersecção ou ainda quando uma trajetória em rota de colisão aumenta ou reduz a velocidade de modo a evitar outra trajetória em sua rota, conforme exemplo da Figura 1.



**Figura 1. Exemplos de padrões de *avoidance* nas trajetórias (t1 e t2) que evitam outras trajetórias pela mudança de direção (A, B) ou pelo incremento ou redução da velocidade (D) e em trajetórias que evitam regiões estáticas (C)**

Este artigo tem por objetivo apresentar um algoritmo inédito capaz de identificar este novo padrão comportamental, mais especificamente aquele que ocorre quando um objeto móvel evita determinada região espacial, como no exemplo C da Figura 1. O artigo está organizado da seguinte forma: A seção 2 trata da heurística proposta para a detecção da ocorrência do padrão comportamental *avoidance*. Na seção 3, um algoritmo construído com base na heurística proposta é apresentado. Experimentos e resultados são apresentados na seção 4 e a conclusão na seção 5.

## 2. Heurística para detecção do *avoidance*

Para facilitar o entendimento do padrão comportamental *avoidance*, tomemos como exemplo a análise de trajetórias de veículos em regiões monitoradas por câmeras de segurança. Cada câmera tem um determinado ângulo e distância onde as imagens são captadas. Esta região de alcance da câmera pode ser considerada como uma região estática na qual algumas trajetórias irão atravessar enquanto outras, eventualmente,

mudarão seu percurso de modo a evitá-la. O termo estático, aqui relacionado à região da câmera, é utilizado neste trabalho para diferenciar os dados das regiões que são fixas no espaço como regiões de monitoramento, zonas de segurança, obstáculos, etc, daqueles que apresentam um comportamento dinâmico como ocorre nas trajetórias dos objetos móveis. Estas regiões estáticas serão tratadas como objeto alvo e podem ser qualquer tipo de objeto geográfico convexo (linha, polígono, ponto, etc). Dependendo do tipo de objeto geográfico utilizado, o objeto alvo deve ser envolvido por um buffer para permitir o teste de interseção.

No exemplo das câmeras de vigilância, o padrão comportamental *avoidance* ocorre, em termos gerais, quando um objeto móvel está indo em direção a uma região monitorada por câmeras, muda de direção evitando cruzar pela área onde será filmado. Outros objetos, porém, cruzam pela região monitorada sem a intenção de evitá-la, portanto não apresentando o padrão comportamental procurado.

É importante considerar que um veículo trafegando a uma considerável distância da região monitorada, como em um outro bairro, por exemplo, pode não ser relevante para a análise em questão, pois o fato de estar em rota para uma câmera de vigilância a muitas quadras de distância não indica, necessariamente, que uma mudança de direção seja no intuito de evitar ser filmado. Desta forma, é necessário definir uma região específica onde a procura pelo novo padrão comportamental será realizada. Tal região, denominada *região de interesse*, é formada por um buffer de raio  $d$ , cujo valor é informado pelo usuário e cujo centro coincide com o centro do objeto alvo.


A Figura 2 ilustra um exemplo de como a região de interesse se dispõe ao redor do objeto alvo e da forma com que as trajetórias se relacionam com esta região. O buffer que forma a região de interesse limita a análise das trajetórias até uma distância específica do objeto alvo. Assim, as trajetórias que se encontram a uma distância maior que  $d$  serão descartados da análise, pois uma eventual mudança de direção fora desta área não seria considerada como intenção de evitar o objeto alvo, tal como o exemplo da trajetória t3 da Figura 2. A definição de um valor maior para  $d$  pode incluir a trajetória t3 na análise se a mesma interceptar a região de interesse, tornando-a relevante desta forma.

Ainda com relação à Figura 2, a trajetória t1 intercepta a região de interesse e não intercepta o objeto alvo, apresentando um comportamento que sugere a intenção de evitá-lo. Já a trajetória t2, embora intercepte a região de interesse, intercepta também o objeto alvo, não apresentando a intenção de evitá-lo, de forma que, neste contexto, não é considerado um possível *avoidance*.

A busca pelo padrão comportamental *avoidance* inicia pela seleção dos pontos das trajetórias que interceptam as regiões de interesse dos objetos alvo. Cada uma destas trajetórias é avaliada em busca das características principais do padrão comportamental procurado, onde: (a) a trajetória deve estar indo em direção ao objeto alvo e, num dado instante, mudar de direção de forma a evitá-lo, de modo que não ocorra nenhuma interseção com este; (b) **a porção da trajetória que está na direção do objeto alvo, aqui denominada subtrajetória, direcionada ao alvo, deve ser maior ou igual a um valor especificado pelo usuário.**

A condição “b” é necessária para reduzir os falsos positivos que podem ocorrer em casos de pequenas manobras dentro da área de interesse, imprecisão dos aparelhos de

captura ou dados corrompidos.



**Figura 2. Exemplo da região de interesse, objeto alvo e comportamento de trajetórias**

A heurística proposta não consegue identificar quando uma trajetória muda de direção com a única intenção de evitá-la ou quando foi obrigado a evitá-la. Assim, para reduzir este problema, foi definido um índice de confiança global, por trajetória, o qual permite identificar quais trajetórias apresentaram o padrão comportamental procurado, de forma mais ostensiva, servindo desta forma para localizar trajetórias com comportamentos suspeitos ou fora da normalidade.

Cada trajetória possui um valor de confiança global  $Av_t$  que é atribuído com base no cálculo dos valores de confiança local  $Av_i$ . A fórmula do cálculo do fator de confiança global é mostrada na Figura 3.

$$Av_t = \frac{\sum_{i=1}^n Av_i}{n}$$

Onde:  
 $n$  é o número de regiões de interesse interceptadas pela trajetória  $t$ .

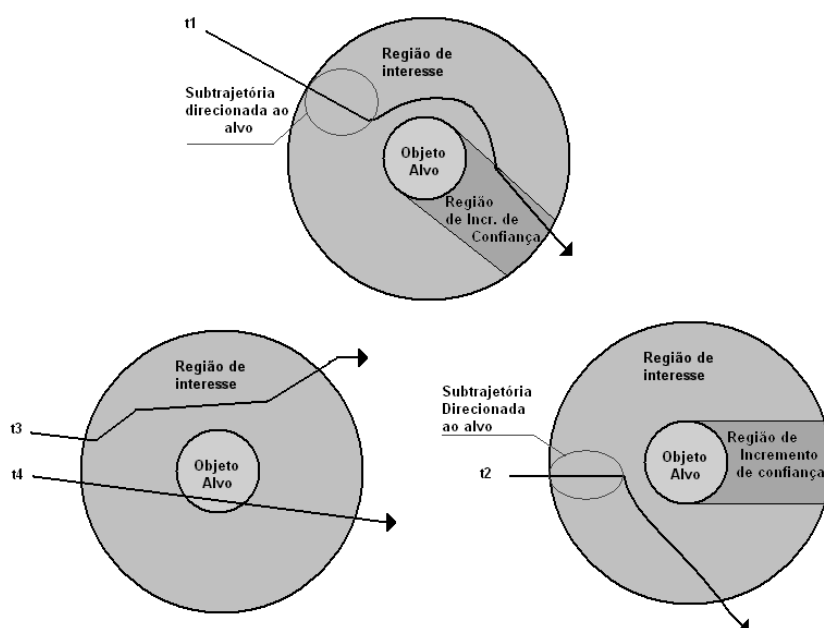
**Figura 3. Fórmula para cálculo do fator de confiança global.**

Quando uma trajetória, após evitar o objeto alvo, retoma seu trajeto original, é possível supor com maior grau de confiança que a mudança de direção teve por objetivo principal evitar a interseção com o objeto alvo. A verificação deste comportamento é realizada testando-se interseção da trajetória com uma região denominada região de incremento de confiança, a qual 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 mais seu buffer, se existir. A região de incremento de confiança é única para cada trajetória considerada. A Figura 4 mostra exemplos de como esta região é posicionada dentro da região de interesse.

O valor de confiança local  $Av_i$  é atribuído a cada interseção de uma trajetória com uma região de interesse e pode ser: *none* (valor 0), *weak* (valor 0,5) ou *strong* (valor 1). Quando uma trajetória intercepta a região de interesse, mas não evita o objeto alvo ou ainda, quando o evita mas não apresenta uma subtrajetória direcionada ao alvo com tamanho mínimo informado, então o valor *none* é atribuído. Quando uma trajetória

intercepta a região de interesse e evita o objeto alvo, cumprindo a exigência de uma subtrajetória direcionada ao alvo com um valor válido sem, entretanto, interceptar a região de incremento de confiança, então o valor *weak* é atribuído. Já quando todos os requisitos desta última são satisfeitos e, além disso, a trajetória intercepta a região de incremento de confiança, então o valor *strong* é dado à confiança local desta trajetória neste objeto alvo.

No exemplo da Figura 4, a trajetória t1 possui uma subtrajetória direcionada ao alvo de tamanho válido e intercepta a região de incremento de confiança, recebendo um valor de confiança local de *strong*. 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 recebe o valor *weak* para confiança local. A trajetória t3 não apresenta uma subtrajetória direcionada ao alvo com tamanho válido e a trajetória t4 intercepta o objeto alvo, assim ambas recebem *none* como valor de confiança local. É importante lembrar que o tamanho mínimo da subtrajetória direcionada ao alvo é fornecido pelo usuário de modo que, se o valor for pequeno o bastante, t3 pode ser considerado um possível *avoidance* para este objeto alvo e receberá um valor de confiança local *weak*.



**Figura 4. Exemplos da região de incremento de confiança e da subtrajetória direcionada ao alvo.**

### 3. Algoritmo para detecção de *avoidance*

Com base na heurística definida no capítulo 2, foi criado um algoritmo para detectar possíveis ocorrências do padrão comportamental *avoidance* cujo pseudocódigo é apresentado na Figura 5.

A linha 13 da Figura 5 faz uma chamada a uma função de cálculo da subtrajetória direcionada ao alvo. Esta subtrajetória é a maior porção da trajetória que intercepta a

região de interesse e que está se deslocando em direção ao objeto alvo. Para ser válida, o seu tamanho deve ser igual ou maior que o valor informado pelo usuário.

Para determinar se esta subtrajetória existe e se tem tamanho válido, o algoritmo seleciona todos os pontos da trajetória que interceptam a região de interesse e, então, computa a distância de cada trecho entre os pontos, armazenando o maior valor válido encontrado.

```

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

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

Método:

1. Início
2. Se Subt é nula
3.     Subt ← (d - b)·0,1 // Atribui tamanho default se não informado
4. Fim Se
5. // Seleciona os pontos das trajetórias que interceptam a região de interesse
6. t ← Select * from T where intersects (T, buffer (O, d))
7. Para cada ti ∈ t faça
8.     Para cada ok ∈ O faça
9.         Se intersects (ti, buffer (ok, b)) // Testa interseção com objeto alvo
10.            tauxik ← none // atribui confiança local para este avoidance
11.        Senão
12.            // Verifica subtrajetória direcionada ao alvo
13.            Se Subtrajetoria(ti) ≥ Subt
14.                // Verifica interseção com região de incremento de confiança
15.                RegIncr ← Calcula região de incremento de confiança
16.                Se intersects (ti, RegIncr)
17.                    tauxik ← strong
18.                Senão
19.                    tauxik ← weak
20.            Senão
21.                tauxik ← none
22.            Fim Se
23.        Fim Para
24.    Fim Para
25.    Calcula AVti
26. Fim Para
27 Fim

```

**Figura 5. Pseudocódigo do algoritmo para detecção de *avoidance*.**

Para determinar se a trajetória está no caminho do objeto alvo, o algoritmo calcula o ângulo máximo que esta a trajetória pode assumir permanecendo na direção do objeto alvo. A fórmula para cálculo do ângulo  $\alpha$  é apresentada na Figura 6.

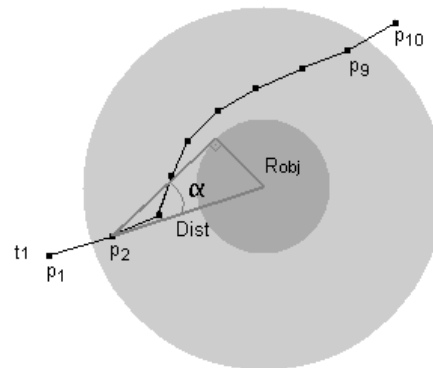
Uma vez calculado o ângulo  $\alpha$ , o algoritmo obtém o azimute entre  $P_i$  e  $P_{i+1}$  e o azimute entre o  $P_i$  e o centro do objeto alvo. Se a diferença entre estes ângulos for menor que  $\alpha$ , então o algoritmo considera que a trajetória está efetivamente na direção do objeto alvo.

$$\alpha = \arcsin\left(\frac{R_{Obj}}{\sqrt{Dist^2 + R_{Obj}^2}}\right)$$

Onde:

$R_{Obj}$ : tamanho do buffer do objeto alvo;

Dist: a distância entre  $P_i$  e o ponto central do objeto alvo;



(a)

(b)

**Figura 6. Em (a) fórmula para cálculo de  $\alpha$  e (b) representação gráfica dos valores envolvidos.**

O pseudocódigo da rotina de identificação da subtrajetória direcionada ao alvo é mostrado na Figura 7. Dentro da região de interesse o ângulo da trajetória pode oscilar, apresentando várias subtrajetórias que, em determinado momento, vão em direção ao objeto alvo. O método apresentado na Figura 7 foi desenvolvido para identificar a maior destas trajetórias como sendo a subtrajetória direcionada ao alvo.

Um valor mínimo *default* para considerar a subtrajetória direcionada ao alvo válida, foi definido como sendo 10% do raio da região de interesse descontado o raio do objeto alvo e seu buffer, se existir. Por exemplo, se o raio entre o centro do objeto alvo e sua borda for de 10m e o raio da região de interesse for de 50m, a distância mínima que a trajetória deve percorrer em direção ao obstáculo antes de mudar de direção é

$$(50 - 10) \cdot 10\% = 4\text{m}$$

para ser considerada um possível *avoidance*. Este percentual foi definido com base nos experimentos realizados, onde o fator de 10% se mostrou suficientemente robusto em todas as situações testadas. Se o usuário considerar o valor *default* não apropriado pode fornecer outro valor.

**Entrada:** P // Conjunto de pontos da trajetória que interceptam a região de interesse  
c // Centro do objeto alvo

**Saída:** dist // Maior distância que a trajetória percorreu em direção ao alvo

**Método: Subtrajetória()**

```
1. Início
2.   i ← 1
3.   próximo ← i + 1
4.   dist ← 0
5.   distaux ← 0
6.   Repete até o final de P
7.       Calcula  $\alpha$  (c, Pi, Ppróximo)
8.       ap ← azimute (Pi, Ppróximo)
9.       ac ← azimute (Pi, c)
10.      Se |ac - ap| <  $\alpha$ 
11.          distaux ← Calcula a distância entre Pi e Ppróximo
12.          Se distaux > dist
13.              dist ← distaux
14.          Fim Se
15.          próximo ← próximo + 1
16.      Senão
17.          i ← i + 1
18.          próximo ← i + 1
19.      Fim Se
20.  Fim Repete
21.  Return dist
22. Fim
```

**Figura 7. Pseudocódigo para identificar a subtrajetória direcionada ao alvo.**

#### 4. Experimentos e resultados

Para comprovar a eficácia do algoritmo experimentos foram realizados 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 determinação de evitarem algumas regiões específicas, mapeadas como objetos alvo.

Todas as trajetórias foram capturadas por aparelho GPS e armazenadas em base de dados PostgreSQL com a extensão PostGIS. O algoritmo foi desenvolvido em Java com auxílio do IDE NetBeans. Exemplos das tabelas com as trajetórias e os objetos alvo são mostrados na Figura 8.

Como já descrito, o objeto alvo pode ser qualquer tipo de geometria convexa (ponto, reta, plano). Nos experimentos realizados optou-se pelo uso de pontos por uma questão de simplificação.



tid	gid	the_geom
0	15	POINT(-51.1776695251 -30.0196628571)
0	16	POINT(-51.1776695251 -30.0196628571)
...	...	...
1	334	POINT(-51.1768875122 -30.0200634003)
1	335	POINT(-51.1769294739 -30.0200443268)
...	...	...

(a) tabela de trajetórias

gid	the_geom
0	POINT(-51.1774244 -30.0197681)
1	POINT(-51.1769097 -30.0199839)
2	POINT(-51.1766656 -30.0202229)
3	POINT(-51.1764379 -30.0203136)
4	POINT(-51.1772694 -30.0199922)
...	...

(b) tabela de objetos alvo

Figura 9. Exemplo de tabelas de trajetórias e objetos alvo.

Para os experimentos foram coletadas 26 trajetórias de carro 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 suspeito, evitando as regiões monitoradas.

Sendo trajetórias coletadas em veículos, admite-se que os pontos acompanharão o contorno das vias de tráfego. Essa informação é importante para definir os valores informados como parâmetro para o algoritmo.


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

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

Na Figura 9 é possível visualizar parte das trajetórias 4, 17 e 22 obtidas de carro e como elas se relacionam com o objeto alvo 3. Neste trecho a trajetória 22 intercepta o buffer do 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.

A Figura 10 mostra em (a) o índice de confiança global por trajetória informado ao término da execução do algoritmo, e em (b) parte da tabela *avoidance* gerada pelo algoritmo, onde a trajetória 4 evitou os objetos alvo 3 e 5, a trajetória 17 evitou o objeto alvo 3 e a trajetória 23 evitou o objeto alvo 5.

A tabela auxiliar *avoidance* contém a identificação do objeto alvo (gid) e da trajetória (tid) que gerou a ocorrência de *avoidance*, o tamanho em metros da subtrajetória direcionada ao alvo (Dist), o valor da confiança local (LocalConf) e duas colunas adicionais que contém, consecutivamente, a representação geométrica da região de interesse (RegAvoidance) e da região de incremento de confiança (RegIncrConf). Estes campos são úteis para identificação visual das regiões de possível *avoidance* e conseqüente região de incremento de confiança, quando da utilização de aplicativos visuais de apoio a GIS.



**Figura 9. Visualização de parte de trajetórias obtidas de carro em relação ao objeto alvo 3.**

Tid	Confiança
4	0.75
17	0.5
23	0.5
...	...

(a) saída do algoritmo

Tid	Gid	Dist	LocalConf	RegAvoidance	RegIncrConf
4	3	18.90	1	POLYGON((,...	POLYGON((,...
4	5	37.15	0.5	POLYGON((,...	POLYGON((,...
17	3	20.12	0.5	POLYGON((,...	POLYGON((,...
23	5	9.11	0.5	POLYGON((,...	POLYGON((,...
...	...	...	...	...	...

(b) tabela *avoidance*

**Figura 10. Exemplo das saídas do algoritmo de detecção de *avoidance*.**

Para os experimentos com trajetórias de pedestres, foram coletadas dez trajetórias em uma praça onde foram definidos sete objetos alvo como regiões de monitoramento. Nestes testes informou-se 2m como buffer do objeto alvo e 20m como buffer da região de interesse. Como tamanho mínimo para a subtrajetória direcionada ao alvo utilizou-se 2m. A Figura 11 mostra a tabela *avoidance* gerada com a execução do algoritmo com os parâmetros informados.

Tid	Gid	Dist	LocalConf	RegAvoidance	RegIncrConf
1	5	2.12	0.5	POLYGON((,...	POLYGON((,...
6	3	2.38	0.5	POLYGON((,...	POLYGON((,...
6	6	11.04	0.5	POLYGON((,...	POLYGON((,...

**Figura 11. Tabela *avoidance* para trajetórias de pedestres.**

## 5. Conclusão

Este artigo apresentou 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 na cidade de Porto Alegre. O algoritmo desenvolvido identificou com sucesso as trajetórias que evitaram as regiões estáticas informadas como objeto alvo, tanto nos pontos obtidos a pé quanto naqueles obtidos de carro, retornando o resultado esperado conforme os valores de buffer do objeto alvo e da região estática foram variados. Testes em maior escala serão realizados para avaliar o comportamento e a performance do algoritmo com um volume de dados maior.

## AGRADECIMENTOS

FAPESC, CNPQ

## 6. Referências

- Alvares, L. O.; Bogorny, V.; Kuijpers, B.; Macedo, J. A. F.; Moelans, B.; Vaisman, A.: 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 (2007).pp. 162-169.
- Benkert, M., Gudmundsson, J., Hübner, F., Wolle, T.: Reporting flock patterns. In: Algorithms - ESA 2006, Proceedings. Volume 4168 of Lecture Notes in Computer Science. Springer-Verlag Berlin, Berlin (2006) 660–671
- Bogorny, V. and Wachowicz, M. A Framework for Context-Aware Trajectory Data Mining. In: Longbing Cao, Philip S. Yu, Chengqi Ahang, Huaifeng Zhang. (Org.). Data Mining for Business Applications. Springer, 2008.
- Bogorny, V.; Kuijpers, B.; Alvares, L.O. ST-DMQL: A Semantic Trajectory Data Mining Query Language. In: International Journal of Geographical Information Science. Taylor and Francis, 2009.
- Gudmundsson, J.; Kreveld, M.. Computing longest duration flocks in trajectory data. In GIS'06: Proceedings of the 14th annual ACM international symposium on Advances in geographic information systems, pages 35–42, New York, NY, USA, 2006. ACM Press.
- Laube, P., van Kreveld, M., Imfeld, S.: 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, DE (2004) 201–214.
- Mining Traffic condition from trajectories. Fifth International Conference on Fuzzy Systems and Knowledge Discovery (pp. 256-260). Shandong, China: IEEE Computer Society.
- Palma, A. T; Bogorny, V.; Kuijpers, B.; Alvares, L.O. 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 (2008) Brazil. pp. 863-868.