

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO

**Identificando padrões comportamentais do tipo
avoidance em trajetórias de objetos móveis**

por

ALISSON MOSCATO LOY

Dissertação submetida à avaliação, como
requisito parcial para a obtenção do grau de
Mestre em Ciência da Computação.

Prof. Dr. Luis Otávio Álvares
Orientador

Porto Alegre, agosto de 2011.

CIP – CATÁLOGO NA PUBLICAÇÃO

Loy, Alisson Moscato

Identificando padrões comportamentais do tipo *avoidance* em trajetórias de objetos móveis / Alisson Moscato Loy – PPGC da UFRGS, 2011.

58 f.:il.

Orientador: Luis Otávio Álvares; Co-orientador: Vânia Bogorny.

Dissertação (mestrado) – Universidade Federal do Rio Grande do Sul. Programa de Pós-Graduação em Computação, Porto Alegre, BR-RS, 2011.

1. Trajetórias de Objetos Móveis. 2. Padrões Comportamentais. 3. Descoberta de Conhecimento. 4. Inteligência Artificial. I Álvares, Luis Otávio. II Bogorny, Vânia. III Identificando padrões comportamentais do tipo *avoidance* em trajetórias de objetos móveis.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitor: Prof. Carlos Alexandre Netto

Vice-Reitor: Prof. Rui Vicente Oppermann

Pró-Reitor de Pós-Graduação: Prof. Aldo Bolten Lucion

Diretor do Instituto de Informática: Prof. Flávio Rech Wagner

Coordenador do PPGC: Prof. Álvaro Freitas Moreira

Bibliotecária-Chefe do Instituto de Informática: Beatriz Regina Bastos Haro

Agradecimentos

Meus sinceros agradecimentos a todos que me apoiaram, em sentimentos, ações ou orações, nesse importante passo em minha vida, o qual sempre considere fundamental para minha carreira e para minha evolução como ser humano. Em especial...

Minha família...

Somos todos humanos. Nosso tempo é limitado! Nosso corpo é limitado! Nossa paciência e ânimo, limitados! Quando nos aplicamos num crescimento pessoal, nosso tempo para os outros diminui, nosso stress aumenta, nossa ausência é um fato. Aqueles que mais amamos e que estão mais próximos são os primeiros a sentir e os mais afetados pela mudança de rotina exigida para cumprir as metas estipuladas. Mais ainda, no meu caso, onde uma jornada dupla de trabalho/mestrado exigiu de todos paciência e perdão. Não há palavras que possam agradecer o incentivo, a motivação e o esforço em ajudar que recebi de minha esposa e de meus filhos amados. A eles minha gratidão e dívida eterna pelo tempo que me ausentei, envolvido por meus estudos. Obrigado!

Agradeço aos meus irmãos pelo constante incentivo e por festejarem sempre minhas conquistas, em toda minha vida, na forma mais pura e sincera de amizade e companheirismo.

Em meu coração, desejo que meus pais, onde estiverem, celebrem plenamente esse momento, já que da memória deles provém todo o incentivo em prosseguir meus estudos e me aperfeiçoar técnica, social e humanamente.

Meus mestres...

Inicio agradecendo aos professores da faculdade que me apoiaram de forma ímpar para que fosse possível entrar no PPGC da UFRGS, em especial ao professor Dr. André Cordenonsi e Msc. Guilherme Dhein.

Então, que grande honra, tornei-me orientando de dois Doutores na melhor definição da palavra. Pessoas sensatas, inteligentes e humanas, tal qual todo orientador deveria ser.

Agradeço a oportunidade, a paciência, o incentivo e a confiança por ter seus nomes avalizando o trabalho hora apresentado. Obrigado Dr. Luis Otávio Álvares e Dra. Vânia Bogorny.

Amigos e colegas...

Obrigado a todos que entenderam que minha ausência era por um motivo importante e respeitaram e apoiaram minhas prioridades.

Obrigado a todos que vibraram com minha conquista, celebrando comigo o término dessa etapa.

Contem comigo, amigos!

Sumário

LISTA DE FIGURAS	5
LISTA DE TABELAS.....	7
RESUMO	8
ABSTRACT	9
1 INTRODUÇÃO	10
1.1 CONTEXTUALIZAÇÃO	10
1.2 MOTIVAÇÃO	11
1.3 OBJETIVOS.....	13
1.4 ESTRUTURA DA DISSERTAÇÃO	13
2 ESTADO DA ARTE.....	14
3 HEURÍSTICA PARA IDENTIFICAÇÃO DO PADRÃO COMPORTAMENTAL <i>AVOIDANCE</i>..	20
4 ALGORITMO PARA DETECÇÃO DE <i>AVOIDANCE</i>.....	31
4.1 PSEUDOCÓDIGO PRINCIPAL.....	31
4.2 PSEUDOCÓDIGO PARA IDENTIFICAÇÃO DA SUBTRAJETÓRIA DIRECIONADA AO ALVO	33
4.3 PSEUDOCÓDIGO PARA GERAÇÃO DA REGIÃO DE INCREMENTO DE CONFIANÇA	37
5 EXPERIMENTOS E RESULTADOS.....	40
5.1 EXPERIMENTO 1 - TRAJETÓRIAS DE VEÍCULOS EM PORTO ALEGRE - RS	40
5.2 EXPERIMENTO 2 - TRAJETÓRIAS DE VEÍCULOS EM XANGRI-LÁ - RS	45
5.3 EXPERIMENTO 3 - TRAJETÓRIAS OBTIDAS POR PEDESTRES EM PARQUE PÚBLICO	48
5.4 GRÁFICOS COMPARATIVOS E CONSIDERAÇÕES SOBRE OS EXPERIMENTOS.	51
6 CONCLUSÕES E TRABALHOS FUTUROS.....	53
REFERÊNCIAS BIBLIOGRÁFICAS	55

Lista de figuras

FIGURA 1.1 – TRAJETÓRIAS DE PEDESTRES EM UM PARQUE PÚBLICO NA CIDADE DE PORTO ALEGRE.....	10
FIGURA 1.2 - EXEMPLOS DE OCORRÊNCIAS DO PADRÃO COMPORTAMENTAL <i>AVOIDANCE</i>	12
FIGURA 2.1 - CONSTRUÇÃO DA MATRIZ DE ANÁLISE RELATIVA DE MOVIMENTO (REMO) PARA O PARÂMETRO AZIMUTE (ADAPTADA DE LAUBE (2002)).....	14
FIGURA 2.2 - PADRÃO <i>FLOCK</i> (ADAPTADA DE BENKERT (2006)).....	15
FIGURA 2.3 – APLICAÇÃO DO ALGORITMO <i>T-PATTERN MINNER</i> EM UMA BASE DE TRAJETÓRIAS DE VEÍCULOS TRAFEGANDO NO RIO DE JANEIRO.	16
FIGURA 2.4 – EXEMPLO DO PROCESSO GERAL DE DETECÇÃO DE <i>OUTLIERS</i> DO ALGORITMO TRAOD (ADAPTADO DE LEE (2008)).....	18
FIGURA 2.5 – DISTRIBUIÇÃO DAS ZONAS DE ALERTA E PROTEÇÃO AO REDOR DA AERONAVE (ADAPTADO DE SHANDY (2001))......	19
FIGURA 3.1. EXEMPLO DA REGIÃO DE INTERESSE, OBJETO-ALVO E COMPORTAMENTO DAS TRAJETÓRIAS.	22
FIGURA 3.2 – EXEMPLO DE SUBTRAJETÓRIA DIRECIONADA AO ALVO.	22
FIGURA 3.3 – EXEMPLO DE COMPORTAMENTOS DA TRAJETÓRIA QUANDO REALIZA O <i>AVOIDANCE</i>	23
FIGURA 3.4 – EXEMPLO DO FORMATO E DISPOSIÇÃO DA REGIÃO DE INCREMENTO DE CONFIANÇA.	24
FIGURA 3.5 – EXEMPLO DE TRAJETÓRIA QUE INTERCEPTA MÚLTIPLAS REGIÕES DE INTERESSE.	25
FIGURA 3.6 – EXEMPLO DO CÁLCULO DO PERCENTUAL DE <i>AVOIDANCE</i> POR REGIÃO DE INTERESSE.....	27
FIGURA 3.7 – EXEMPLO DE EXCLUSÃO DO OBJETO-ALVO O ₂ POR POSSUIR 100% DE <i>AVOIDANCE</i>	27
FIGURA 3.8 – EXEMPLO DE OBJETOS-ALVO COM E SEM A INTERSEÇÃO DE TRAJETÓRIAS.	28
FIGURA 3.9 – EXEMPLO DE <i>AVOIDANCE</i> DESCONSIDERADO PELA REFERÊNCIA DA TABELA DE EVENTOS.....	29
FIGURA 4.1 - PSEUDOCÓDIGO DO ALGORITMO PARA DETECÇÃO DE <i>AVOIDANCE</i>	32
FIGURA 4.2 - PSEUDOCÓDIGO PARA IDENTIFICAR A SUBTRAJETÓRIA QUE VAI EM DIREÇÃO AO ALVO.	34
FIGURA 4.3 – EXEMPLO DA IDENTIFICAÇÃO DA SUBTRAJETÓRIA EM DIREÇÃO AO ALVO	35
FIGURA 4.4 – EXEMPLO DE IDENTIFICAÇÃO DA SUBTRAJETÓRIA EM DIREÇÃO AO ALVO QUANDO DA OCORRÊNCIA DE TRAJETÓRIA COM MUITOS PONTOS DENTRO DA REGIÃO DE INTERESSE.....	36
FIGURA 4.5 – EXEMPLO DE OCORRÊNCIAS DE SUBTRAJETÓRIAS DIRECIONADAS AO ALVO.	37

FIGURA 4.6 – PSEUDOCÓDIGO DA FUNÇÃO QUE GERA A REGIÃO DE INCREMENTO DE CONFIANÇA	38
FIGURA 4.7 – EXEMPLO DE REGIÃO DE INCREMENTO DE CONFIANÇA PARA OBJETO-ALVO NÃO CIRCULAR.....	39
FIGURA 4.8 – EXEMPLO DA INTERFERÊNCIA DO PONTO INICIAL DA SUBTRAJETÓRIA DIRECIONADA AO ALVO NA CRIAÇÃO DA REGIÃO DE INCREMENTO DE CONFIANÇA. 39	
FIGURA 5.1 – VISUALIZAÇÃO NO <i>GOOGLE MAPS</i> DAS TRAJETÓRIAS OBTIDAS POR VEÍCULOS NA CIDADE DE PORTO ALEGRE	41
FIGURA 5.2 – RESULTADO EM TELA APÓS A EXECUÇÃO DO ALGORITMO PARA OS DADOS DE TRAJETÓRIA DE VEÍCULOS EM PORTO ALEGRE SEM USO DA TABELA DE EVENTOS.....	42
FIGURA 5.3 – TRAJETÓRIAS OBTIDAS POR VEÍCULOS EM PORTO ALEGRE, COM AS OCORRÊNCIAS DE <i>AVOIDANCE</i> DETECTADAS PELO ALGORITMO.	43
FIGURA 5.4– RESULTADO EM TELA APÓS A EXECUÇÃO DO ALGORITMO PARA OS DADOS DE TRAJETÓRIA DE VEÍCULOS EM PORTO ALEGRE COM USO DA TABELA EVENTOS.....	44
FIGURA 5.5 – EXEMPLO DE TRAJETÓRIAS OBTIDAS POR VEÍCULOS TRAFEGANDO NA CIDADE DE XANGRI-LÁ E OBJETOS-ALVO INFORMADOS NO EXPERIMENTO 2.	46
FIGURA 5.6 - RESULTADO EM TELA APÓS A EXECUÇÃO DO ALGORITMO PARA OS DADOS DE TRAJETÓRIA DE VEÍCULOS EM XANGRI-LÁ.....	47
FIGURA 5.7 – <i>AVOIDANCES</i> DETECTADOS NO OBJETO-ALVO 0 PARA TRAJETÓRIAS DE VEÍCULOS CAPTURADAS NA CIDADE DE XANGRI-LÁ.....	47
FIGURA 5.8 – TRAJETÓRIAS DE PEDESTRES NO PARQUE GERMÂNIA EM PORTO ALEGRE VISUALIZADAS NO <i>GOOGLE EARTH</i>.	48
FIGURA 5.9 - RESULTADO EM TELA APÓS A EXECUÇÃO DO ALGORITMO PARA OS DADOS DE TRAJETÓRIA DE PEDESTRES NO PARQUE GERMÂNIA, EM PORTO ALEGRE.	49
FIGURA 5.10 - TRAJETÓRIAS OBTIDAS POR PEDESTRES NO PARQUE GERMÂNIA COM OCORRÊNCIAS DE <i>AVOIDANCE</i> DETECTADAS.....	50
FIGURA 5.11 – GRÁFICO COMPARATIVO ENTRE O NÚMERO TOTAL DE PONTOS NAS TRAJETÓRIAS E O NÚMERO DE PONTOS DENTRO DE ALGUMA REGIÃO DE INTERESSE.	51
FIGURA 5.12 – GRÁFICO COMPARATIVO ENTRE A QUANTIDADE DE OBJETOS-ALVO, <i>AVOIDANCE</i> IDENTIFICADOS E TRAJETÓRIAS QUE INTERCEPTARAM ALGUMA REGIÃO DE INTERESSE.....	51
FIGURA 5.13 – GRÁFICO COMPARATIVO DOS TEMPOS MÉDIOS DE EXECUÇÃO NOS DIFERENTES EXPERIMENTOS.	52

Lista de tabelas

TABELA 3.1 – EXEMPLO DA TABELA DE EVENTOS PARA REDUZIR FALSAS OCORRÊNCIAS DE <i>AVOIDANCE</i>.	30
TABELA 3.2 – EXEMPLO DOS DADOS DA TRAJETÓRIA MOSTRADA NA FIGURA 3.9.	30
TABELA 5.1 – EVENTOS INFORMADOS PARA TESTE DOS DADOS DE VEÍCULOS EM PORTO ALEGRE.	44

Identificando padrões comportamentais do tipo *avoidance* em trajetórias de objetos móveis

Resumo

Com o aumento na disponibilidade e considerável redução de custo das tecnologias que permitem a obtenção de dados de objetos móveis, torna-se abundante a oferta de dados de trajetórias. O estudo dessas trajetórias tem por objetivo permitir uma melhor compreensão dos dados, bem como a extração de novo conhecimento utilizando técnicas computacionais. Um tipo de estudo que pode ser realizado é a análise do comportamento das trajetórias de objetos móveis. 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 ou espaço-tempo. Este trabalho propõe a formalização de um novo padrão comportamental que indique quando um objeto móvel está evitando determinadas regiões espaciais. Este padrão foi denominado *avoidance*. A identificação e o estudo de tal comportamento pode ser de interesse de diversas áreas tais como segurança, jogos eletrônicos, comportamento social, entre outros. Inicialmente, este trabalho apresenta uma heurística com base nas observações das ocorrências do evento *avoidance*. A partir daí, são definidas as formalizações deste novo padrão. É apresentado, também, um algoritmo para identificar automaticamente o padrão comportamental *avoidance* em trajetórias de objetos móveis. Para avaliar a eficácia deste algoritmo, ao final desta dissertação são apresentados resultados de experimentos realizados em trajetórias coletadas por pedestres e por veículos em diversos locais da cidade de Porto Alegre e Xangri-lá.

Palavras-Chave: Trajetórias de objetos móveis, padrões comportamentais, descoberta de conhecimento, inteligência artificial.

Identifying avoidance behavior patterns in moving objects trajectories

Abstract

With the increasing availability and considerable price reduction of technologies that allow the collection of moving object data, the offering of trajectory data becomes abundant. The study of these trajectories has the objective to allow a better understanding of the data, as well as the extraction of new knowledge using computational techniques. One of the possible studies is the analysis of the behavior of moving objects. The study on behavior patterns in trajectories has focused on agglomeration and similarity of entities moving in space or space and time. This work proposes the formalization of a new behavior pattern that indicates when a moving object is avoiding some determined spatial region, here called avoidance. The study and identification of this behavior may be of interest in many application areas, like security, electronic games, social behavior, and so on. Initially, this work presents an heuristic based on the observations of avoidance events, and based on this heuristic we define the formalization of this new kind of trajectory behavior pattern. This work also presents an algorithm to automatically identify this behavior in trajectories of moving objects. To evaluate the effectiveness of this algorithm, experiments were performed on trajectory datasets, collected by pedestrians in a park, and by vehicles at several places in the cities of Porto Alegre and Xangri-lá.

KeyWords: *Moving objects trajectories, behavior patterns, kdd, artificial intelligence.*

1 Introdução

Neste capítulo é apresentada uma contextualização acerca do assunto geral aqui tratado, as principais motivações para realização do trabalho, os objetivos e a forma como está organizada esta dissertação.

1.1 Contextualização

A crescente redução de custos e a disponibilidade de novas tecnologias de rastreamento de objetos móveis, tais como aparelhos GPS, sensores de posicionamento, identificadores RFID e aparelhos celulares, tem como resultado um incremento na quantidade de dados de trajetórias de objetos móveis disponíveis na forma bruta. Tais dados são objeto de pesquisa em diversas áreas da Tecnologia da Informação, sob os mais amplos aspectos tais como social, biológico, econômico, técnico, entre outros.

No mundo que nos cerca há inúmeras situações que envolvem fenômenos espaço-temporais que são focos de pesquisa e análise, como padrões de comportamento de pessoas em compras, movimento de migração de animais, movimentação de pessoas em parques e cidades, fluxo de veículos, movimento de embarcações, entre outros.



FIGURA 1.1 – Trajetórias de pedestres em um parque público na cidade de Porto Alegre

O estudo do comportamento das trajetórias desses objetos móveis busca transformar essa massa de dados brutos em informações úteis para o processo de tomada de decisão, descoberta do conhecimento e interpretação da realidade. Sua aplicação pode contribuir na resolução de problemas, na identificação de tendências e padrões ou na identificação de comportamentos de exceção (*outliers*) e apresenta-se como uma área multidisciplinar dentro da Tecnologia da Informação, despertando o interesse de subáreas

como sistemas de informações geográficas, banco de dados, descoberta de conhecimento em dados espaciais e mineração de dados. A Figura 1.1 mostra um exemplo de trajetórias de pedestres em um parque na cidade de Porto Alegre, visualizadas no *Google Earth*.

Dados brutos de trajetórias são capturados como uma seqüência de pontos no formato (id, x, y, t) , onde (x, y) representam as coordenadas geográficas do objeto id no instante de tempo t . Desta forma, uma trajetória é o caminho descrito por um objeto móvel em função do tempo e, sendo dados brutos, são isentos de qualquer tipo de informação semântica que possa auxiliar na extração de conhecimento. Esse conjunto de geometrias que mudam em função do tempo, conforme definido em Gütting (2000), forma um banco de dados espaço-temporal.

1.2 Motivação

Estudos de padrões comportamentais em trajetórias de objetos móveis estão sendo desenvolvidos principalmente sob duas óticas de pesquisa, a semântica (Álvares 2007), (Bogorny 2008) e a geométrica (Laube 2005), (Gudmundsson 2006), (Cao 2007), (Giannotti 2007), (Andersson 2008). Estudos desenvolvidos sob a ótica geométrica buscam descobrir conhecimento a partir de dados brutos sem quaisquer níveis semânticos, senão aqueles que podem ser inferidos a partir do próprio conjunto de dados, e é sob a ótica geométrica que este trabalho foi desenvolvido.

Muitas técnicas são aplicadas aos mais variados conjuntos de trajetórias e buscam descobrir informações não triviais na forma como tais objetos se comportam no tempo e no espaço. Alguns estudos focam na análise de uma trajetória de cada vez enquanto outros levam em consideração mais de uma trajetória, fazendo uso de técnicas como *clustering*, por exemplo.

Freqüentemente o estudo de padrões comportamentais em trajetórias busca encontrar comportamentos espaço-temporais que revelem semelhanças entre as trajetórias (e.g. objetos móveis que trafegam no mesmo caminho, no mesmo intervalo de tempo, realizam paradas nos mesmos locais). 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 característico é denominado neste trabalho como *avoidance*.

O termo *avoidance* é utilizado, principalmente, na área de estudos de imagens e em robótica relacionado à parte do hardware ou software responsável por identificar possíveis obstáculos e tratá-los na aplicação em questão (Bernabeu 2001), (Nedevschi 2009), (Suh 1988), (Suh 1992). Neste trabalho o termo é utilizado para nomear um padrão comportamental característico de objetos móveis que evitam determinadas regiões espaciais.

A Figura 1.2 traz alguns exemplos de trajetórias que apresentam o padrão comportamental *avoidance*. Em (A, B) trajetórias (t_1 e t_2) evitam interseção com outras

trajetórias pela mudança de direção. Em (D) os objetos móveis evitam se encontrar na mesma posição espacial alterando a velocidade (incremento ou redução) de um ou ambos. Em (C) está um exemplo de trajetória que muda de direção para evitar determinada região espacial.

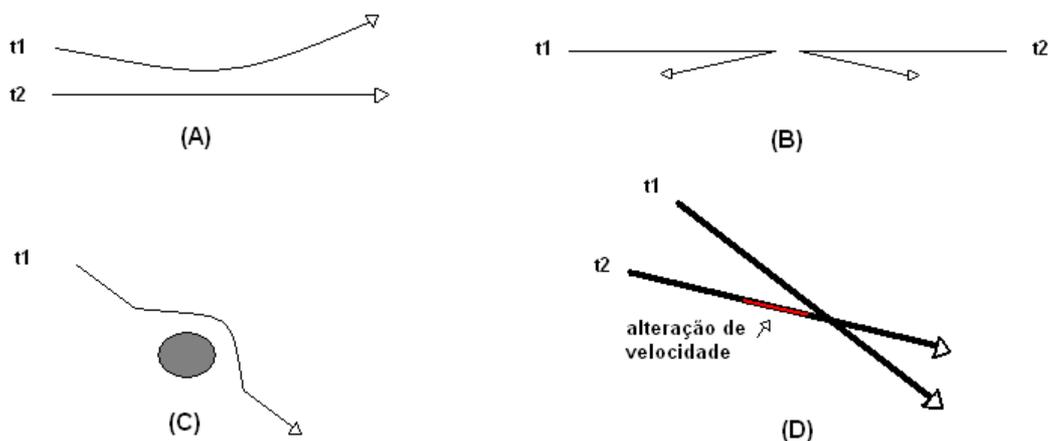


FIGURA 1.2 - Exemplos de ocorrências do padrão comportamental *avoidance*

Espera-se que pessoas comuns transitando em aeroportos ou shoppings ignorem a presença de câmeras de vigilância e postos de segurança e transitem sem qualquer intenção de evitar ser filmado. Assim uma pessoa que descreva uma trajetória que evite interceptar as regiões de captura das câmeras ou, ainda, evite ficar ao alcance da visão dos postos de segurança enquanto transita pelo ambiente, apresentam um comportamento de exceção comparado aos demais. Este trabalho é focado na construção de um método para identificação deste novo tipo de padrão comportamental, mais especificamente aquele que ocorre quando um objeto móvel evita uma determinada região espacial, como no exemplo (C) da Figura 1.2.

A identificação deste novo padrão comportamental pode ser útil, por exemplo, em aplicações na segurança de áreas internas e externas identificando comportamentos suspeitos de pessoas ou veículos em uma região monitorada por câmeras de segurança, na análise de trânsito, sugerindo rotas alternativas baseadas em conhecimento subjetivo, nos jogos eletrônicos permitindo o estudo do comportamento do adversário frente a determinadas situações de ambiente, em estudos de comportamentos sociais, entre outros.

A idéia de se identificar padrões comportamentais que permitam reforçar questões relevantes à área de segurança não é nova. Existem trabalhos na área de detecção de movimentos que buscam identificar movimentos suspeitos com base em seqüências de imagens como realizado por Soldera (2007). Tais algoritmos comumente fazem uso das imagens capturadas por câmeras, analisando-as quadro a quadro buscando identificar comportamentos suspeitos. O algoritmo proposto neste trabalho não se propõe a substituir tal técnica, já que avalia o comportamento de trajetórias previamente capturadas, atribuindo valores de confiança maiores quanto maior for a característica de evitar cruzar por regiões monitoradas.

1.3 Objetivos

O objetivo geral deste trabalho é elaborar um método que identifique o padrão comportamental *avoidance* em trajetórias de objetos móveis em relação a regiões espaciais pré-definidas.

Como objetivos específicos podem ser listados:

1. Definir heurísticas que caracterizem a ocorrência de *avoidance* em uma trajetória;
2. Formalizar as definições envolvidas na identificação de *avoidance*;
3. Desenvolver um algoritmo que identifique automaticamente as ocorrências de *avoidance*;
4. Comprovar a eficácia do algoritmo desenvolvido através de experimentos com diferentes grupos de trajetórias;

1.4 Estrutura da Dissertação

Os capítulos restantes deste trabalho estão organizados da seguinte forma:

Capítulo 2 - **Estado da arte:** Neste capítulo são apresentados os principais trabalhos relacionados ao tema desta dissertação, conceitos e fundamentos relacionados aos padrões comportamentais de trajetórias de objetos móveis sob a análise geométrica.

Capítulo 3 - **Heurística para identificação do padrão comportamental *avoidance*:** Neste capítulo são apresentadas as condições fundamentais para existência do padrão comportamental *avoidance*, sua validação e seus graus de confiança.

Capítulo 4 – **Algoritmo para detecção do *avoidance*:** O objetivo deste capítulo é apresentar o algoritmo criado para identificar o padrão comportamental *avoidance* em diferentes grupos de trajetórias de objetos móveis.

Capítulo 5 – **Experimentos e resultados:** Aqui são apresentados os resultados dos experimentos realizados com trajetórias obtidas por veículos nas cidades de Porto Alegre - RS e Xangri-lá - RS, e com trajetórias obtidas por pedestres em parque público de Porto Alegre.

Capítulo 6 – **Conclusões e trabalhos futuros:** Neste capítulo são apresentadas as considerações finais sobre os assuntos tratados nessa dissertação bem como os trabalhos futuros relacionados ao padrão comportamental proposto.

2 Estado da arte

Dentro do estudo de comportamentos de trajetórias pela análise geométrica, onde se busca extrair conhecimento sem informações semânticas explícitas, Patrick Laube (2002) destacou-se definindo uma coleção de padrões espaço-temporais baseados na direção do movimento e localização do objeto móvel. Neste trabalho foram definidos parâmetros básicos que permitam a identificação de padrões comportamentais em trajetórias, denominada Análise REMO (“*Relative Motion*”). Cada um desses parâmetros (azimute do movimento, variação da velocidade, etc) deve ser apresentado em uma matriz na qual cada linha representa a seqüência de valores do parâmetro em questão para um objeto móvel.

A Figura 2.1 ilustra um exemplo da Matriz REMO. Neste caso, cada linha desta matriz representa, para um objeto móvel específico (O_1 , O_2 , O_3 ou O_4), o valor do azimute do movimento em cada instante de tempo do objeto em questão. Esses valores devem estar ordenados pelo tempo.

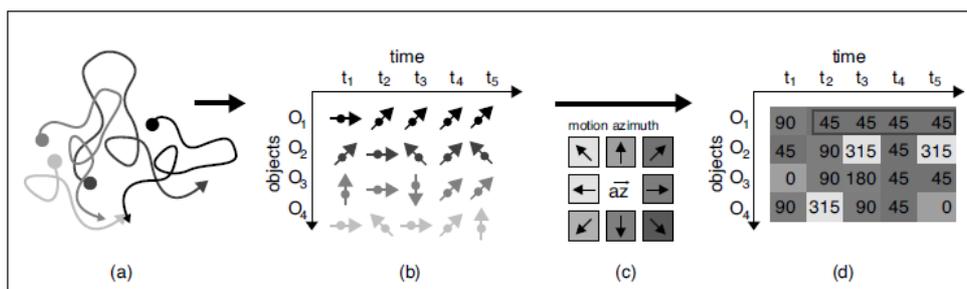


FIGURA 2.1 - Construção da Matriz de Análise Relativa de Movimento (REMO) para o parâmetro azimute (adaptada de Laube (2002))

A Figura 2.1 (d) ilustra um exemplo de um padrão detectado na matriz REMO. Nesta figura, a partir do instante de tempo t_2 , o valor do azimute para o objeto O_1 é constante. Este padrão foi denominado como *constance* em Laube (2002).

Em Laube (2004), foram definidos padrões espaço-temporais focados na relação de grupos de objetos denominados *flock*, *leadership*, *convergence* e *encounter*. Neste trabalho, além da definição destes padrões, os autores disponibilizaram os pseudocódigos dos algoritmos específicos para detectá-los nas trajetórias dos objetos móveis. A ocorrência de tais padrões comportamentais foi definida como:

flock: Ocorre quando um grupo de trajetórias de objetos móveis se desloca de forma conjunta dentro de um dado raio no espaço por um determinado intervalo de tempo pré-definido. Um exemplo da ocorrência deste padrão é mostrado na Figura 2.2.

leadership: Define um deslocamento com padrão de liderança, onde os seguidores devem estar dentro de uma determinada distância de tolerância.

convergence: Padrão de deslocamento que identifica um conjunto de trajetórias que convergem para uma determinada localização em uma dada janela temporal.

encounter: Semelhante ao padrão *convergence* porém as trajetórias devem permanecer juntas num dado raio por um período de tempo.

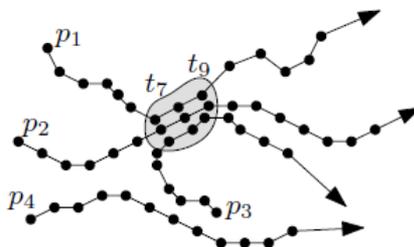


FIGURA 2.2 - Padrão *flock* (adaptada de Benkert (2006))

No trabalho seguinte, Laube (2005) aplicou o conceito de níveis de granularidade temporal de dados. Esta granularidade temporal foi originalmente definida como zoom temporal por Hornsby (2001). Com a aplicação no trabalho de Laube. (2005), foi possível uma representação dos dados em diferentes níveis de detalhe, levando a detecção de diferentes parâmetros de movimento dos objetos móveis ocorridos no grupo.

Em 2006, Benkert (2006) estendeu a definição de *flock* para um conjunto de entidades que se movem próximas uma das outras durante um intervalo de tempo, propondo um novo algoritmo para detecção do *flock*, mais eficiente e que permitisse considerar trajetórias com passos de tempo diferentes. Também Gudmundsson (2006) apresentou uma nova versão do padrão *flock* para identificar padrões de comportamento em trajetórias de longa duração e Gudmundsson (2007) tratou de uma forma mais eficiente para calcular os quatro tipos de padrões geométricos introduzidos por Laube (2004).

Além do trabalho desenvolvido por Laube, outros autores realizaram experimentos com dados de trajetórias de objetos móveis à procura de semelhanças geométricas, temporais ou ambas. Em Giannotti (2007), os autores propõem um novo padrão denominado *trajectory pattern*, o qual representa um conjunto de trajetórias individuais que compartilham a propriedade de visitar a mesma seqüência de lugares com tempos de deslocamento similares. Também é apresentado um algoritmo denominado *T-Pattern Miner* que se propõe a buscar regiões espaciais que aparecem como freqüentemente visitadas e o tempo de transição entre duas dessas regiões consecutivas, no formato denominado como *temporally annotated sequences* (TAS), cuja definição é apresentada inicialmente por Giannotti (2006) e representa padrões seqüenciais agregados aos típicos tempos de transição entre seus elementos.

Um exemplo de TAS aplicado sobre o histórico de navegação de páginas *web* de um usuário pode ser o seguinte:

$$\{ '/' \} \xrightarrow{2} \{ '/papers.html' \} \xrightarrow{90} \{ '/kdd.html' \}^1$$

que corresponde a uma seqüência de navegação que inicia em *root* e após 2 segundos continua em *papers.html* e, finalmente, após 90 segundos termina em *'kdd.html'*.

¹ Adaptado de Giannotti (2007)

O algoritmo *T-Pattern Minner* exige que as regiões geográficas que são consideradas interessantes sejam mapeadas para que seja possível a identificação dos tempos de deslocamento entre elas. Essas regiões são denominadas regiões de interesse (*regions of interest - ROI* em inglês) e podem ser calculadas no algoritmo (*ROI* dinâmicas) ou informadas pelo usuário (*ROI* estáticas). Para o cálculo das regiões de interesse o algoritmo divide o espaço geográfico por onde percorrem as trajetórias em um *grid* e então procura por regiões densas, isto é, regiões que são visitadas por muitas trajetórias. Regiões de interesse podem ser estendidas pela agregação de células consecutivas do *grid*, desde que a densidade de cada uma seja maior ou igual ao valor de *threshold* de cálculo de regiões densas, informado pelo usuário.

Na Figura 2.3 observa-se um exemplo da aplicação do algoritmo *T-Pattern Minner* em uma base de dados de trajetórias capturadas por veículos sonda trafegando na cidade do Rio de Janeiro. Em amarelo as regiões de interesse estáticas definidas como bairros da cidade. Em vermelho os pontos das trajetórias que interceptam cada bairro. A linha em azul ilustra um padrão encontrado pelo algoritmo *T-Pattern Minner*, que neste exemplo significa que um grupo de trajetórias cruza pelos Bairros Barra da Tijuca, Leblon e Botafogo, nesta ordem, com padrões temporais semelhantes.

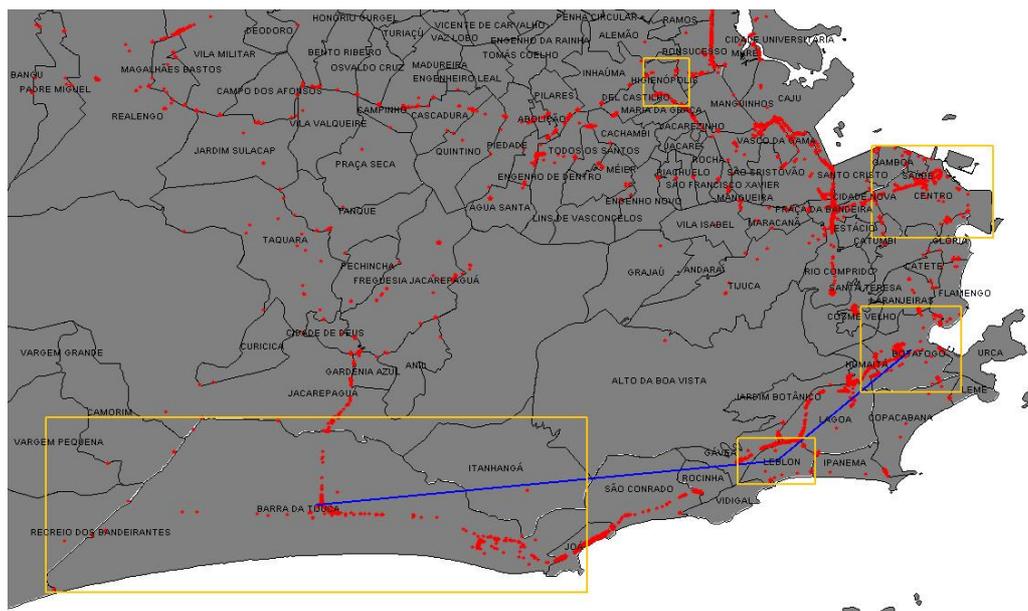


FIGURA 2.3 – Aplicação do algoritmo *T-Pattern Minner* em uma base de trajetórias de veículos trafegando no Rio de Janeiro.

O estudo de padrões comportamentais em trajetórias de objetos móveis também é utilizado como apoio para algoritmos que buscam prever comportamentos futuros com base nos dados históricos de movimento.

Em Cao (2006) o autor apresenta o estudo do relacionamento das trajetórias de diferentes tipos de objetos com base em uma regularidade, denominado no artigo como *Collocation Episodes*. Um *Collocation Episode* é uma seqüência de eventos espaço-temporais, no qual um evento representa um conjunto de objetos se movendo próximos uns dos outros por um mesmo período. Como exemplo da ocorrência deste comportamento, os autores apresentam a seguinte seqüência de eventos: “Uma vez que

um puma esteja se movendo próximo a um veado por 1 minuto, é esperado que um abutre também vá se mover próximo ao mesmo veado nos próximos 3 minutos com alto índice de probabilidade”. Neste exemplo o veado apresenta uma característica especial denominada *centric feature*, pois participa de ambos os eventos (puma-veado, veado-abutre). Para encontrar os *collocation episodes* os autores apresentaram um *framework* de duas fases:

1. É aplicada uma técnica baseada em *hash* para uma busca eficiente dos objetos pares;
2. Os *collocation episodes* são obtidos pela aplicação de algoritmo de mineração. No artigo o autor propõe e compara dois algoritmos, sendo um deles baseado na técnica do *Apriori* e outro no paradigma de mineração vertical.

Já em Elnekave (2007) os autores apresentam uma técnica para predizer a localização futura de um objeto móvel com base no padrão histórico de sua movimentação. Para isso utilizaram uma representação compacta de trajetórias espaço-temporais de onde foram extraídas as trajetórias periódicas de cada objeto móvel com base em medidas de similaridade e, então, aplicadas técnicas de *clustering* que buscam por padrões de comportamentos recorrentes nestas trajetórias. Foi assumido pelos autores que objetos se movem de acordo com algum padrão espaço-temporal periódico (a cada dia, por exemplo). Neste caso, cada objeto pode ser analisado para se determinar características recorrentes em seu deslocamento. Uma vez identificados tais padrões é possível, segundo os autores, predizer a localização de tais objetos móveis em horários específicos.

Como pode ser observado pelos trabalhos aqui relacionados, o foco das pesquisas de padrões comportamentais sob a ótica geométrica é na busca de padrões que representem semelhança e aglomeração. Uma exceção é o trabalho de Lee (2008), no qual é apresentado um algoritmo que busca detectar *outliers* em um conjunto de trajetórias de objetos móveis. Neste trabalho, Lee apresenta um algoritmo denominado TRAOD, que faz uso da técnica *partition-and-detect* para particionar a trajetória em segmentos de linha de acordo com seu comportamento espacial. Após isso, o algoritmo aplica técnicas de detecção baseadas nos conceitos de distância e densidade, que resulta na detecção de dois tipos de *outliers* em trajetórias:

Positional outlier: A localização da trajetória é diferente das outras trajetórias na sua vizinhança.

Angular outlier: A direção da trajetória é diferente das demais trajetórias em sua vizinhança.

A utilização da técnica de particionar a trajetória apresentada por Lee, permite identificar *outliers* em partes distintas da trajetória, assim não é necessário que toda a trajetória apresente um comportamento de exceção para ser identificada pelo algoritmo. Na Figura 2.4 é mostrado um exemplo do processo geral que o algoritmo TRAOD utiliza para identificar *outliers* em trajetórias ou parte de trajetórias.

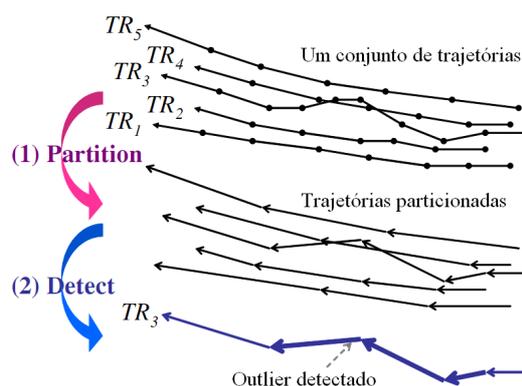


FIGURA 2.4 – Exemplo do processo geral de detecção de *outliers* do algoritmo TRAOD (Adaptado de Lee (2008)).

Em se tratando de trajetórias de objetos móveis, o termo *avoidance* é frequentemente utilizado relacionado a *collision-avoidance*, o que, em linhas gerais, representa o estudo em tempo real do posicionamento e do movimento desses objetos móveis de modo que não se choquem em um instante de tempo futuro. Tais técnicas são aplicadas para diferentes tipos de objetos móveis como carros, barcos e aviões. A seguir são apresentados alguns exemplos de casos de *collision-avoidance*.

Em Kim (2007), os autores realizam o estudo de trajetórias de veículos para evitar colisões traseiras, através da minimização do erro da distância de segurança entre dois veículos em movimento e do ajuste da velocidade relativa entre esses veículos. Para atingir esse objetivo, os autores propõem um controle longitudinal hierárquico.

Já em Liu (2005) os autores propõem uma rede neural de inferência baseada na lógica *fuzzy* para evitar colisões entre navios. O modelo criado possui três subredes que são responsáveis por: i) classificação do navio encontrado em situação de colisão e a ação a ser tomada para evitá-la, ii) calcular a relação de velocidade do navio e iii) inferir o tempo de ação e a magnitude desta para evitar o choque das embarcações.

No estudo de aeronaves, a solução proposta por Shandy (2001) tem como base a interação de três agentes inteligentes para evitar a colisão, agindo de modo colaborativo, da seguinte forma:

Collision agent: Utiliza as informações sobre o tráfego aéreo e processa os dados determinando os conflitos baseados em duas regiões definidas como zona de proteção e zona de alerta, cujo posicionamento ao redor da aeronave é mostrado na Figura 2.5.

Avoidance agent: Verifica as restrições nas priorizações, conferindo a viabilidade das manobras e manipula os conflitos dependendo do tráfego aéreo (táticas e manobras).

Trajectory optimizer: Otimiza os problemas e restrições no cálculo da trajetória.

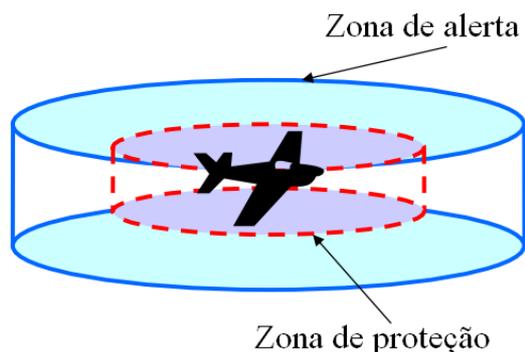


FIGURA 2.5 – Distribuição das zonas de alerta e proteção ao redor da aeronave (Adaptado de Shandy (2001)).

O termo *avoidance* também é bastante utilizado na área da robótica, relacionado à rotina que trata do planejamento dos movimentos futuros de um robô, de modo a evitar o choque com outros robôs ou obstáculos no ambiente. Como exemplo dessa abordagem é possível citar Suh (1992). Neste trabalho os autores propõem um novo método de planejamento de trajetórias através de esquemas de controle de tráfego. Este controlador de tráfego determina a próxima posição de cada robô com base nas prioridades de movimento, nos limites físicos do robô e nas condições para eliminação de possível colisão. A solução para o planejamento de trajetórias livres de colisão é baseada em expressões algébricas para o cálculo das trajetórias ótimas de cada robô.

Em Lee (1999) os autores propõem uma técnica que permite calcular um caminho livre de colisão para dois robôs operando próximo um do outro, como manipuladores industriais computadorizados. Nesse artigo os autores fazem uso de círculos ou esferas concêntricas em cada robô para discretizar o espaço utilizado por ele e assim poder calcular um caminho livre de colisão para manipulação de ambos os robôs no mesmo espaço-tempo.

Outro exemplo relacionado à utilização do termo *avoidance* na área da robótica é encontrado em Suh (1988). Neste artigo os autores apresentam e aplicam o conceito de tubo na solução de problemas de *collision-avoidance*. Um espaço livre de colisões é representado por um tubo articulado através de parâmetros como pontos de referência e caminhos alternativos. Ao objeto móvel que se desloca dentro deste tubo, é garantido um caminho livre de obstáculos e colisões.

O presente trabalho difere dos demais trabalhos aqui relacionados na medida em que propõe o estudo das características das trajetórias de objetos móveis onde seja possível identificar um novo padrão comportamental que indique quando um objeto-móvel está evitando uma determinada região espacial.

É importante salientar, também, que o estudo do padrão comportamental *avoidance*, tratado neste trabalho, não se aplica à análise de dados em tempo real. As análises são feitas com base nos dados de trajetórias previamente obtidos e armazenados em locais que permitam sua recuperação e manipulação computacional.

3 Heurística para identificação do padrão comportamental *avoidance*

Neste trabalho considerou-se a seguinte definição de trajetória de objeto móvel:

Definição 1: Uma trajetória t_i é uma seqüência de pontos espaço-temporais $\langle p_0 = (x_0, y_0, t_0), p_1 = (x_1, y_1, t_1), \dots, p_n = (x_n, y_n, t_n) \rangle$, onde $x_i, y_i \in \mathfrak{R}$, $t_i \in \mathfrak{R}^+$ para $i = 0, 1, \dots, n$, e $t_0 < t_1 < t_2 < \dots < t_n$.

O passo inicial para a compreensão do padrão comportamental *avoidance* foi observar quais características eram determinantes em uma trajetória de modo que, dispondo somente de dados geográficos, fosse possível determinar se o objeto móvel evitou determinada região no espaço. Essas situações foram avaliadas para dois casos: i) quando o objeto-móvel é limitado por uma rede viária (e.g. veículos trafegando nas ruas e avenidas de uma cidade), e ii) para os casos de trajetórias não restritas, ou seja, que podem seguir caminhos diversos (e.g. pessoas caminhando em um parque, em animais em migração ou barcos em atividade de pesca). A partir da análise do comportamento de cada trajetória frente a uma determinada região espacial a ser evitada, foi possível determinar um padrão e então formular definições para o problema aqui tratado.

Como já citado anteriormente o estudo do padrão comportamental *avoidance* pode ser aplicado em diversas áreas do conhecimento porém, para uma melhor compreensão das variáveis envolvidas, foi utilizado neste capítulo um exemplo de aplicação específico na área de segurança. Neste contexto será explicado o comportamento *avoidance* utilizando o exemplo de pessoas caminhando em regiões monitoradas por câmeras de vigilância.

Uma câmera de vigilância 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 designar regiões que não mudam de localização geográfica durante todo o processo de identificação das ocorrências de *avoidance*. Tal característica pode ser encontrada em áreas de monitoramento, zonas de segurança, obstáculos, entre outros. Estas regiões estáticas são tratadas neste trabalho pelo termo objeto-alvo. Dependendo do tipo de objeto geográfico utilizado, o objeto-alvo deve ser envolvido por um *buffer*, sendo que neste caso o objeto-alvo passa a ser considerado toda a geometria, incluindo seu *buffer*.

Definição 2: Objeto-alvo o : Objeto geográfico convexo com área maior que zero. Objetos representados por ponto ou linha devem ser envolvidos por um *buffer*.

Considerando o exemplo das câmeras de segurança, o padrão comportamental *avoidance* ocorre quando um objeto móvel está indo em direção a uma determinada câmera e muda de direção evitando cruzar pela área de captura de imagem, enquanto o comportamento natural esperado é que um objeto móvel cruze pela região monitorada sem apresentar a intenção de evitá-la.

Com isso tem-se a primeira condição para existência de um *avoidance*:

A trajetória deve estar na direção do objeto-alvo e, num dado instante, mudar de direção de forma a evitá-lo, de modo que não ocorra nenhuma interseção desta trajetória com este objeto-alvo.

Observou-se, também, que muitas trajetórias vão na direção do objeto-alvo e mudam seu caminho em um ponto muito distante deste como, por exemplo, um veículo trafegando em um outro bairro ou uma pessoa caminhando no lado oposto de um parque. Neste caso uma mudança de direção dificilmente será na intenção de evitar tal objeto-alvo e desta forma não é relevante para a análise em questão. Com isso definiu-se uma região específica onde a procura pelo padrão comportamental será realizada. Tal região foi denominada região de interesse.

Definição 3: região de interesse r : é a região correspondente ao objeto-alvo o_j envolvido por um *buffer* de tamanho d .

A Figura 3.1 mostra 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 ou partes de trajetórias que se encontrem a uma distância maior que d serão descartadas da análise, pois uma eventual mudança de direção fora desta área não seria considerada como sendo na intenção de evitar este objeto-alvo, tal como o exemplo da trajetória t_3 da Figura 3.1, a qual não é considerada relevante neste exemplo. A opção por um valor maior para o parâmetro d pode incluir a trajetória t_3 na análise se a mesma interceptar a região de interesse, tornando-a relevante desta forma.

Com base neste raciocínio, novas condições são necessárias para a correta identificação do padrão comportamental procurado:

Para ser considerado um *avoidance* a trajetória deve interceptar a região de interesse do objeto-alvo;

A mudança de direção da trajetória que caracteriza a intenção de evitar a interseção com o objeto-alvo deve ocorrer dentro da região de interesse que envolve este objeto-alvo.

Ainda com relação à Figura 3.1, a trajetória t_1 intercepta a região de interesse e não intercepta o objeto-alvo, apresentando um comportamento que sugere a intenção de evitá-lo. Já a trajetória t_2 , 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 *avoidance*.

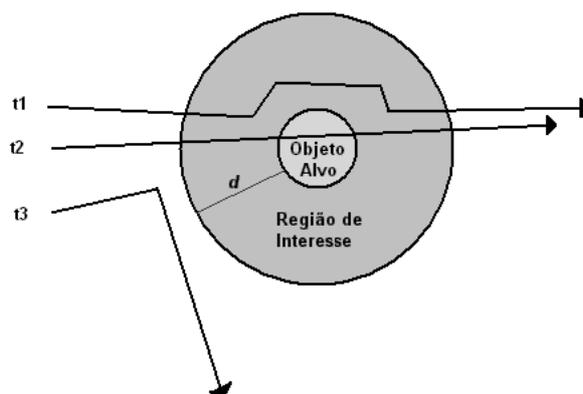


FIGURA 3.1. Exemplo da região de interesse, objeto-alvo e comportamento das trajetórias.

Após a definição da região de interesse observou-se que, mesmo interceptando a região de interesse e não cruzando pelo objeto-alvo, algumas trajetórias não apresentaram um comportamento claro de estar indo na direção ao objeto-alvo antes de mudar de direção. Assim, não foi possível atribuir a tais trajetórias um comportamento suspeito, em se tratando do exemplo das câmeras de vigilância. Isso pode ocorrer em caso de pequenas manobras dentro da região de interesse, erro nos dados, imprecisão, entre outros fatores.

Para tornar mais robusta a identificação do padrão comportamental, foi definido que o objeto móvel deve se deslocar por um percurso mínimo dentro da região de interesse em direção ao objeto-alvo antes de mudar de direção, para só então ser considerado um *avoidance*. O tamanho mínimo desta porção de trajetória, denominada subtrajetória direcionada ao alvo, dependente do contexto da aplicação e do tipo de dado de trajetória que está sendo avaliado, assim seu valor tem natureza dinâmica e deve ser fornecido pelo usuário especialista.

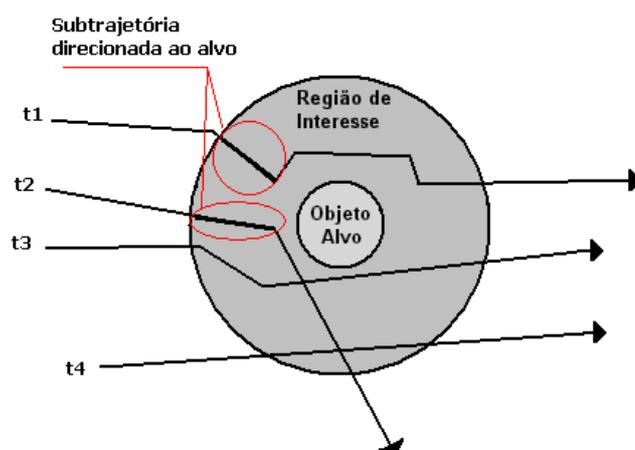


FIGURA 3.2 – Exemplo de subtrajetória direcionada ao alvo.

Definição 4: subtrajetória direcionada ao alvo s_i : é a maior porção de uma trajetória t_i que vai em direção ao objeto-alvo o_j dentro da região de interesse e que tenha um comprimento maior ou igual a l .

A Figura 3.2 ilustra esse conceito. Neste exemplo as trajetórias t_1 e t_2 apresentam subtrajetórias que em determinado instante, dentro da região de interesse, vão na direção do objeto-alvo. A trajetória t_3 apresenta uma subtrajetória muito pequena ($<l$), não caracterizando a intenção clara de ir em direção ao objeto-alvo. Já a trajetória t_4 não possui uma subtrajetória direcionada ao alvo. É importante salientar que, para a porção de trajetória que vai em direção ao alvo dentro da região de interesse receber a denominação de subtrajetória direcionada ao alvo, ela deve ser maior ou igual ao valor de l , caso contrário a subtrajetória direcionada ao alvo não existirá.

Com essa definição uma outra condição para existência do *avoidance* é acrescentada:

A trajetória deve apresentar uma subtrajetória direcionada ao alvo.

Com a inclusão dessa nova condição de existência, é possível criar uma definição para o padrão comportamental *avoidance*, como segue:

Definição 5: uma trajetória t_i apresenta um *avoidance* A_v em relação ao objeto-alvo o_j se intercepta a região de interesse de o_j , possui uma subtrajetória direcionada ao alvo e não intercepta o objeto-alvo o_j .

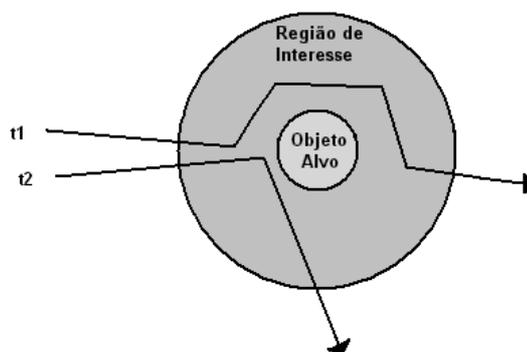


FIGURA 3.3 – Exemplo de comportamentos da trajetória quando realiza o *avoidance*.

Observando o comportamento das trajetórias de objetos móveis que evitam uma câmera de vigilância, conforme exemplificado na Figura 3.3, observa-se que algumas trajetórias retomam seu caminho original após evitar a câmera, como em t_1 , enquanto outras seguem pelo novo caminho, como a trajetória t_2 . Intuitivamente é possível considerar que o comportamento *avoidance* é mais forte naquela trajetória que, após evitar a câmera de vigilância, retorna ao seu trajeto original, como se a única ou maior motivação para a mudança de direção fosse exatamente não ser flagrada pela câmera de segurança.

Com o objetivo de testar se a trajetória retorna para seu caminho original criamos uma região de teste de interseção denominada região de incremento de confiança. Esta região é única para cada trajetória considerada em uma região de interesse. A Figura 3.4 mostra exemplos de como esta região é posicionada dentro da região de interesse.

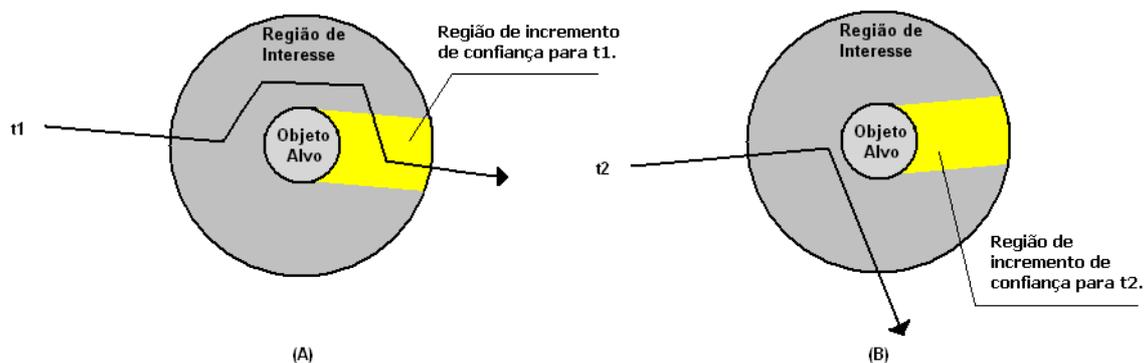


FIGURA 3.4 – Exemplo do formato e disposição da região de incremento de confiança.

Definição 6: região de incremento de confiança u : é uma região contida na região de interesse r , que não inclui o objeto-alvo o e está situada entre o objeto-alvo e a borda da região de interesse r no lado oposto ao primeiro ponto da subtrajetória direcionada ao alvo s . A largura dessa região será definida pela área delimitada por duas retas paralelas e tangentes ao objeto-alvo, com uma inclinação dada pelo ângulo formado por uma linha que liga o centro geométrico do objeto-alvo ao primeiro ponto da subtrajetória direcionada ao alvo.

Pela Definição 6, é possível concluir que, se o objeto-alvo é uma região circular, como nos exemplos até aqui mostrados, a largura da região de incremento de confiança corresponde ao diâmetro do objeto-alvo. Para regiões não circulares, a largura da região de incremento de confiança depende da posição das retas paralelas tangentes ao objeto-alvo e da posição do ponto inicial da subtrajetória direcionada ao alvo, de modo que cada formato diferente de objeto-alvo irá gerar uma região de incremento de confiança diferente. Um exemplo de região de incremento de confiança para objeto-alvo não circular é mostrado no capítulo 4.

Na Figura 3.4 a trajetória t_1 apresenta um *avoidance* com maior grau de certeza pois intercepta a região de incremento de confiança (A), enquanto que a trajetória t_2 realiza o *avoidance* mas não intercepta a região de incremento de confiança, resultando em um menor grau de certeza (B). Com isso é possível caracterizar dois graus de confiança para a ocorrência do *avoidance*. Esse comportamento é mapeado como um índice de confiança local do *avoidance*, conforme definição:

Definição 7: Confiança local Av_{ik} assume os seguintes valores:

Weak avoidance (0,5): trajetória t_i que em relação ao objeto-alvo o_k não intercepta a respectiva região de incremento de confiança.

Strong avoidance (1,0): trajetória t_i que em relação a um objeto-alvo o_k intercepta a respectiva região de incremento de confiança em um tempo posterior a subtrajetória direcionada ao alvo.

O valor de confiança local denominado Av_{ik} é atribuído a cada interseção de uma trajetória com uma região de interesse e pode ser: *weak* (valor 0,5) ou *strong* (valor 1,0), da seguinte forma:

$Av_{ik} = weak$: Quando uma trajetória intercepta a região de interesse, tem uma subtrajetória direcionada ao alvo e evita o objeto-alvo;

$Av_{ik} = strong$: Quando uma trajetória intercepta a região de interesse, tem uma subtrajetória direcionada ao alvo, evita o objeto-alvo e ainda intercepta a região de incremento de confiança;

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, Av_{ik} recebe *none* (valor 0,0), o que significa que não houve ocorrência de *avoidance*.

Até agora foi considerado na análise somente um objeto-alvo. Mas o que acontece se o objeto móvel passar por uma região com várias câmeras?

É muito provável que o objeto móvel se deslocando no espaço intercepte mais de uma região de interesse e em cada uma delas esse objeto pode apresentar um comportamento distinto realizando o *avoidance* com diferentes graus de certeza ou simplesmente interceptando as regiões dos objetos-alvo. Desta forma pode-se definir, além da confiança local de cada interseção da trajetória com uma região de interesse, um índice de confiança global, cuja finalidade é permitir avaliar o comportamento de toda a trajetória em relação aos objetos-alvo informados, indicando aquelas que apresentam, com maior grau de certeza um comportamento suspeito ou de exceção, característico do padrão comportamental aqui descrito. A Figura 3.5 ilustra esse conceito.

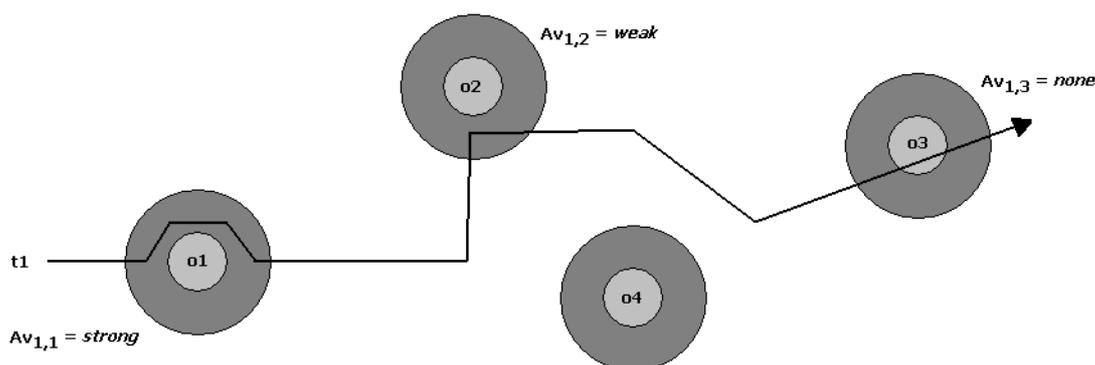


FIGURA 3.5 – Exemplo de trajetória que intercepta múltiplas regiões de interesse.

Na Figura 3.5 é possível visualizar a trajetória $t1$ que intercepta as regiões de interesse dos objetos-alvo o_1 , o_2 , e o_3 . No objeto-alvo o_1 , a trajetória realiza um *avoidance* com confiança local *strong*. No objeto-alvo o_2 , a trajetória realiza *avoidance* sem interceptar a região de incremento de confiança, recebendo grau *weak* para confiança local. A interseção de $t1$ com o_3 não caracteriza o comportamento *avoidance* pois a

trajetória intercepta o objeto-alvo recebendo o valor *none* como confiança local. A trajetória t_1 não intercepta em nenhum momento a região de interesse do objeto-alvo o_4 , assim não há qualquer atribuição de confiança local para este objeto-alvo.

Da mesma forma que uma mesma trajetória pode interceptar diversas regiões de interesse, uma única região de interesse pode ser interceptada por diversas trajetórias distintas como ocorre, por exemplo, em uma câmera de monitoramento posicionada em um cruzamento de avenidas movimentadas. Espera-se que num comportamento normal nem todas as trajetórias evitem tal região monitorada, com algumas interceptando a região de captura da imagem, ou seja, o objeto-alvo.

Partindo do pressuposto que a ocorrência do padrão comportamental aqui descrito seja um comportamento de exceção, um alto índice de *avoidance* em um único objeto-alvo leva a crer que um evento desconhecido obstruiu o fluxo normal de trajetórias em um dado período de tempo, fazendo com que os objetos móveis que transitaram por aquela região evitassem o objeto-alvo por motivo de força maior, como no caso de obras em vias públicas, acidentes, eventos sociais, enchentes, entre outros. Pela heurística aqui descrita (Definição 5), o comportamento de evitar o objeto-alvo será identificado como *avoidance*, resultando em um falso positivo.

Com o objetivo de identificar e minimizar as ocorrências de falsos positivos na identificação do padrão comportamental *avoidance*, é calculado um índice de confiança local por região de interesse Pr_k . Este índice é calculado como sendo o percentual de trajetórias que realizam *avoidance* naquele objeto-alvo em relação ao total de trajetórias que interceptam esta região de interesse.

Esse percentual serve de referência na identificação de falsas ocorrências de *avoidances*, permitindo ao usuário uma validação das situações detectadas pois, uma vez que o índice de confiança local por região de interesse seja muito elevado, tais ocorrências podem ser objeto de uma avaliação mais precisa e podem passar a ser tratados como um evento conhecido. A forma de tratar eventos conhecidos de modo que não gerem falsas ocorrências de *avoidance* é explicada no final deste capítulo.

Definição 8: Percentual de *avoidance* por região de interesse Pr_k :

$$Pr_k = \frac{\sum_{i=1}^m (Av_{ik})^0}{m}, \text{ para } Av_{ik} > 0$$

Onde:

m corresponde ao número de trajetórias que interceptam a região de interesse r_k e Av_{ik} é a medida de *avoidance* da trajetória t_i em relação ao objeto-alvo o_k .

Utilizou-se o expoente 0 (zero) para garantir que sejam computadas todas as ocorrências de *avoidances* identificadas nesta região de interesse, mesmo para o caso em que Av_{ik} seja *weak* (valor 0,5).

A Figura 3.6 mostra um exemplo do cálculo de Pr_k para três regiões de interesse r_1 , r_2 , e r_3 , no qual se observa que todas as trajetórias que interceptaram a região de

interesse r_2 realizaram *avoidance*. Levando em consideração que o *avoidance* é um comportamento de exceção, um valor de 100% sugere que havia um impedimento que bloqueou o fluxo normal das trajetórias que interceptariam o objeto alvo, de modo que essas são falsas ocorrências de *avoidance* pois, provavelmente, não houve a intenção de evitar ser filmado, levando em consideração o exemplo das câmeras de segurança.

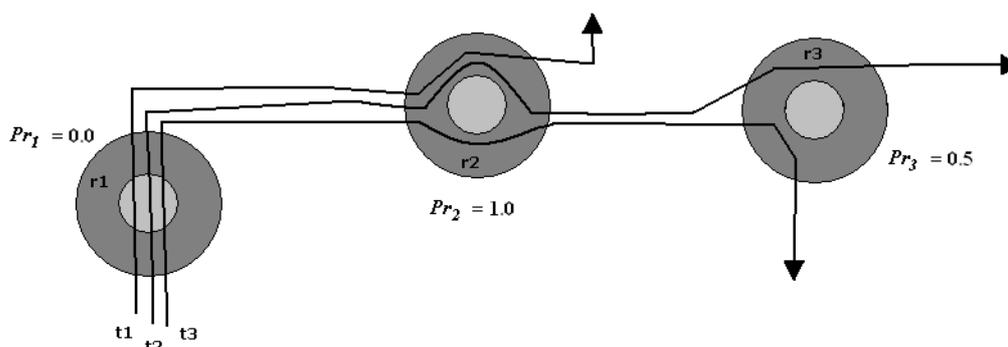


FIGURA 3.6 – Exemplo do cálculo do percentual de *avoidance* por região de interesse.

Para evitar que essas ocorrências afetem os cálculos dos índices de confiança das trajetórias, quando ocorrer 100% de *avoidance* para uma mesma região de interesse o objeto-alvo é eliminado da análise. Assim, o exemplo da Figura 3.6 passaria a ter dois objetos-alvo conforme exemplo apresentado na Figura 3.7, onde o objeto-alvo o_2 foi eliminado por apresentar $Pr_2 = 1.0$.

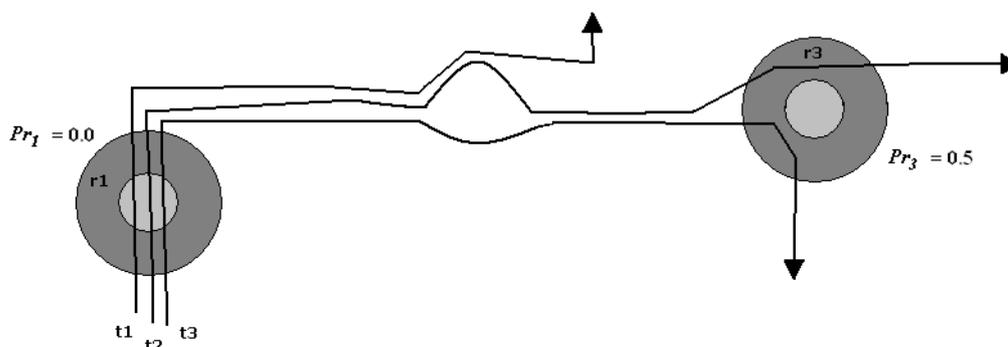


FIGURA 3.7 – Exemplo de exclusão do objeto-alvo o_2 por possuir 100% de *avoidance*.

Ainda analisando o comportamento de múltiplas trajetórias se relacionando com múltiplos objetos-alvo, observou-se que há casos onde nenhuma trajetória intercepta um determinado objeto-alvo onde há *avoidances* identificados. Observou-se, ainda, que tal situação não é tratada pela Definição 8, explicada acima, já que o percentual de *avoidance* deste objeto-alvo não atinge 100%, de modo que o objeto-alvo não é removido. A Figura 3.8 exemplifica essa situação.

Observando a figura supomos que, se t_2 cruzou pela região do objeto alvo o_1 , havia um caminho válido e desimpedido que permitiu tal interseção. Assim, se t_1 realizou *avoidance* em o_1 , é possível supor com maior grau de certeza que sua principal intenção

foi de evitar a interseção com o1 o que, no exemplo das câmeras, equivale a evitar ter sua imagem registrada.

Não há nenhuma trajetória que intercepta o objeto-alvo o2. Desta forma não é possível afirmar se havia um caminho desimpedido que permitisse a interseção de t1 com o2, dando margem a uma falsa ocorrência de *avoidance*.

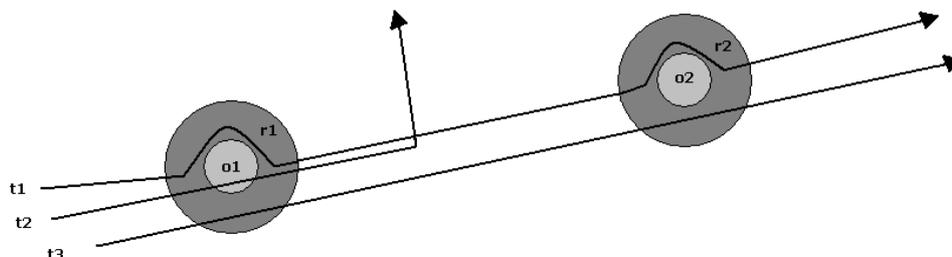


FIGURA 3.8 – Exemplo de objetos-alvo com e sem a interseção de trajetórias.

É possível considerar que a presença ou a ausência de uma trajetória interceptando um objeto-alvo reflete na confiança global das trajetórias que realizaram *avoidance* nesse objeto-alvo. Desta forma, é possível atribuir um maior grau de certeza para aquelas ocorrências de *avoidance* identificadas em objetos-alvo onde exista, pelo menos, uma outra trajetória que o intercepte.

Para ser possível mensurar matematicamente tal efeito, foi atribuído ao objeto-alvo um fator de ponderação conforme a Definição 9.

Definição 9: A Ponderação w_k , em relação ao objeto alvo o_k , assume o seguinte valor para o cálculo da confiança global do *avoidance*:

- 1,0: quando existe pelo menos uma trajetória t_i que intercepta o objeto alvo o_k .
- 0,5: quando nenhuma trajetória intercepta o objeto alvo o_k .

No exemplo da Figura 3.8, o fator de ponderação para o objeto-alvo o1 será 1,0 pois a trajetória t2 intercepta o objeto alvo o1. Para o objeto-alvo o2 o fator de ponderação será 0,5, já que nenhuma trajetória intercepta este objeto-alvo.

É importante ressaltar que tanto o cálculo do Pr_k quanto a identificação da ponderação w_k é sensível ao volume de dados de trajetórias fornecidos, sendo mais precisos quanto maior for a quantidade de trajetórias informadas. Desta forma a taxa de acerto da heurística é diretamente proporcional ao volume de dados submetidos à análise.

Para ser possível avaliar o comportamento de todo o percurso da trajetória em relação aos objetos-alvo informados, foi definido um índice de confiança global. Esta confiança global é calculada com base nos valores da confiança local dessa trajetória, de acordo com o comportamento identificado em cada objeto-alvo e tem relação com o fator de ponderação do objeto-alvo onde o *avoidance* foi identificado.

Para que seja possível identificar e remover as ocorrências de *avoidance* geradas indevidamente devido a existência de um evento, é necessário que tal evento seja registrado previamente. Este registro deve conter, no mínimo, um identificador, a geometria e o período de ocorrência do evento, com data e hora de início e data e hora de final, conforme Definição 11.

Definição 11: evento e_i : objeto geográfico com período de existência definido, sendo $e = (id, geometria, início, fim)$.

Um exemplo do uso dessa lista de eventos pode ser visto na Figura 3.9, onde a mudança de direção da trajetória em azul, na porção em destaque, não será identificada como um *avoidance*, pois a região em vermelho está relacionada a um evento na Tabela 3.1 e a data e hora da obtenção dos pontos da trajetória nesta região de interesse está dentro do período de duração do evento, como exemplo da Tabela 3.2.

TABELA 3.1 – Exemplo da tabela de eventos para reduzir falsas ocorrências de *avoidance*.

gid	evento	início	fim	the_geom
0	Manutenção na rede de esgoto	2011-01-17 10:00:00	2011-01-19 15:00:00	LINestring(...)
1	Feira de rua	2011-01-23 06:30:00	2011-01-23 15:00:00	LINestring(...)
...

TABELA 3.2 – Exemplo dos dados da trajetória mostrada na Figura 3.9.

tid	gid	the_geom	time
0	1	POINT(...)	2011-01-18 19:52:19
0	2	POINT(...)	2011-01-18 19:52:20
...

4 Algoritmo para detecção de *avoidance*

Com base na heurística e nos formalismos apresentados foi criado um algoritmo para detectar possíveis ocorrências do padrão comportamental *avoidance* em trajetórias de objetos móveis. Neste capítulo é apresentado o pseudocódigo do algoritmo sendo que, para melhor compreensão, dividiu-se o código em três partes. O pseudocódigo principal é apresentado na Figura 4.1. O pseudocódigo da função que trata da identificação da maior porção da trajetória que vai em direção ao objeto-alvo é apresentada na Figura 4.2 e, finalmente, o pseudocódigo da função que cria a região de incremento de confiança é apresentado na Figura 4.6.

4.1 Pseudocódigo principal

O algoritmo recebe como entrada um conjunto de trajetórias, um conjunto de objetos-alvo, um valor para o *buffer* da região de interesse, a menor distância que a trajetória deve se deslocar em direção ao objeto-alvo para ser considerada uma subtrajetória direcionada ao alvo e, opcionalmente, um conjunto de eventos utilizados para descartar as falsas ocorrências de *avoidance* identificadas. As linhas citadas nos parágrafos seguintes fazem referência ao algoritmo da Figura 4.1.

Como primeiro processamento, as ponderações dos objetos-alvo são ajustadas para o valor 0,5 (linhas 2, 3 e 4). No decorrer do processamento, quando for detectada a interseção de alguma trajetória com o objeto-alvo, a ponderação correspondente será ajustada para o valor 1 (linha 9), conforme Definição 9.

A seguir, é testada a interseção dos pontos das trajetórias com as regiões de interesse de cada objeto alvo (linha 5). Somente os pontos que interceptam alguma região de interesse serão considerados no restante do algoritmo, o que limita a quantidade de dados a serem processados pelo algoritmo, refletindo positivamente na velocidade de processamento.

O passo seguinte é testar se a parte da trajetória que intercepta a região de interesse também intercepta o objeto-alvo. Em caso positivo (linha 8), não é *avoidance*, caso contrário é chamada a função *subtrajetoria()* que calcula e retorna o tamanho da maior porção da trajetória que vai na direção do objeto-alvo e o primeiro ponto dessa subtrajetória dentro da região de interesse (linha 11). Se o tamanho dessa subtrajetória for maior ou igual a l , existirá uma subtrajetória direcionada ao alvo confirmando a ocorrência do *avoidance*. Caso contrário, não existirá *avoidance* (linha 22).

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

Saída: Av_t // Conjunto de graus de confiança de *avoidance* por trajetória

1. Início
2. Para $o_k \in O$ faça
3. $w_k \leftarrow 0,5$ // valor inicial da ponderação
4. Fim Para
5. Para $t_i \in T$ | intersects (t_i , buffer(O , d)) faça // intercepta região de interesse
6. Para $o_k \in O$ faça
7. Se intersects (t_i , o_k) // Testa interseção com objeto-alvo
8. $av_{ik} \leftarrow none$ // não é avoidance
9. $w_k \leftarrow 1$ // ajusta ponderação
10. Senão
11. $S \leftarrow$ Subtrajetoria(t_i , o_k , d) // obtém maior subt. em dir. ao alvo
12. Se $S.dist \geq l$ // é subtrajetória direcionada ao alvo?
13. Se $\neg (\exists e_j \in E \mid$ intersects (o_k , e_j) \wedge período de t_i
está inserido no tempo de validade de e_j)
14. $Ric \leftarrow$ RegIncrConf(o_k , d , $S.ini$) // Calcula região de
// incremento de confiança
15. Se intersects (t_i , Ric) \wedge período de $t_i >$ período de S
// cruza a reg. de incr. de conf. em um tempo
// posterior à subtrajetória direcionada ao alvo.
16. $av_{ik} \leftarrow strong$ // avoidance forte
17. Senão
18. $av_{ik} \leftarrow weak$ // avoidance fraco
19. Fim Se
20. Fim Se
21. Senão
22. $av_{ik} \leftarrow none$ // não é avoidance
23. Fim Se
24. Fim Se
25. Fim Para
26. Fim Para
27. Para cada $o_k \in O$ faça
28. Calcula Pr_k
29. Se $Pr_k = 1$
30. Retira o_k de O
31. Fim se
32. Fim para
33. Para cada $t_i \in T$
34. Calcula Av_{ti}
35. Fim para
36. Retorna Av_t
37. Fim

FIGURA 4.1 - Pseudocódigo do algoritmo para detecção de *avoidance*.

O teste seguinte (linha 13) verifica a ocorrência de evento conhecido informado pelo usuário que explique/obrigue o desvio identificado testando, além da parte espacial, também a interseção temporal entre o período do evento e os pontos da trajetória para garantir que houve relação entre o *avoidance* identificado e o evento informado. Se a interseção espaço-temporal existir, essa ocorrência de *avoidance* é desconsiderada, caso contrário o *avoidance* vai existir e resta calcular se será *strong* ou *weak*. Para isso inicialmente calcula-se a região de incremento de confiança (linha 14) pela chamada da função `RegIncrConf()` cujo pseudocódigo é apresentado na Figura 4.6.

Se a trajetória intercepta a região de incremento de confiança em um tempo posterior à subtrajetória direcionada ao alvo, o *avoidance* é considerado *strong* (linha 16) caso contrário é considerado *weak* (linha 18).

Após a atribuição dos valores locais de *avoidance* para as trajetórias em relação a cada objeto-alvo calcula-se (linhas 27 a 32) o percentual de *avoidance* por região de interesse conforme Definição 8. Quando este percentual for 100% (todas as trajetórias evitaram esse objeto-alvo), o objeto-alvo relacionado a esta região de interesse é retirado do conjunto de objetos-alvo e, portanto, não será considerado no cálculo do *avoidance* global das trajetórias.

O último passo (linhas 33 a 35) é o cálculo do *avoidance* global por trajetória realizado pela fórmula na Definição 10.

4.2 Pseudocódigo para identificação da subtrajetória direcionada ao alvo

A função `subtrajetória()`, utilizada para identificar e calcular o tamanho da maior subtrajetória que vai em direção ao alvo, recebe como entrada o objeto-alvo que está sendo considerado, os pontos da trajetória que interceptam a região de interesse desse objeto-alvo e o tamanho do buffer da região de interesse. Como saída, a função retorna um conjunto de dados formado pela distância euclidiana entre os pontos inicial e final da subtrajetória identificada e o seu ponto inicial. Esse último dado será importante para a definição da região de incremento de confiança.

Conforme o pseudocódigo apresentado na Figura 4.2, observa-se que o procedimento para identificação da subtrajetória direcionada ao alvo inicia com os dois primeiros pontos da trajetória que interceptam a região de interesse do objeto-alvo em análise (linhas 2 e 3) e será realizado para todos os pontos dessa trajetória que estão dentro dessa região de interesse (linha 7).

Primeiramente é calculado o azimute entre esses dois pontos consecutivos para determinar a inclinação da trajetória (linha 8). O objetivo é expandir a semirreta determinada pelos dois pontos em análise, no mesmo sentido da trajetória, por uma distância que garanta a interseção da reta com o objeto-alvo caso a mesma esteja na direção do objeto-alvo. Para tanto, calcula-se a coordenada (x, y) do ponto auxiliar (linhas 9 e 10), o qual será posicionado a uma distância correspondente a duas vezes o valor informado como *buffer* da região de interesse.

Se a semirreta estendida intercepta o objeto-alvo então se considera que o objeto móvel está se deslocando em direção ao objeto-alvo (linha 11). O passo seguinte é calcular a distância euclidiana entre os pontos (linha 12) e armazenar a maior distância para ser informada como tamanho da subtrajetória em direção ao alvo (linha 14).

Enquanto a semirreta estiver na direção do objeto-alvo o ponto inicial é mantido e o teste se repete, alterando-se o ponto consecutivo até que a trajetória não mais esteja indo na direção do objeto-alvo. Neste caso, o ponto inicial é atualizado (linha 19) e o processo segue até a totalidade dos pontos informados como entrada serem avaliados.

<p>Entrada: P // Conjunto de pontos da trajetória que interceptam a região de interesse o // objeto-alvo em análise d // tamanho do buffer da região de interesse em torno do objeto-alvo</p> <p>Saída: $Subt$ // Subtrajetória direcionada ao alvo</p> <p>Método: Subtrajetoria()</p> <ol style="list-style-type: none"> 1. Início 2. $i \leftarrow 1$ 3. próximo $\leftarrow i + 1$ 4. distaux $\leftarrow 0$ 5. $dist \leftarrow 0$ // Inicializa variável 6. $ini \leftarrow P_i$ // Guarda ponto inicial da subtrajetória 7. Repete até o final de P 8. $ap \leftarrow$ azimute ($P_i, P_{próximo}$) // Calcula o azimute entre os pontos 9. $P_{auxx} \leftarrow \text{sen}(ap) \cdot (2 \cdot d) + P_{ix}$ // Calcula coordenada x do ponto auxiliar 10. $P_{auxy} \leftarrow \text{cos}(ap) \cdot (2 \cdot d) + P_{iy}$ // Calcula coordenada y do ponto auxiliar 11. Se intersects (makeline(P_i, P_{aux}), o) // Intercepta o objeto alvo? 12. distaux \leftarrow Calcula distância euclidiana($P_i, P_{próximo}$) 13. Se distaux $>$ $dist$ 14. $dist \leftarrow$ distaux // Guarda maior distância euclidiana 15. $ini \leftarrow P_i$ // Guarda ponto inicial da maior subtrajetória identificada 16. Fim Se 17. próximo \leftarrow próximo +1 18. Senão // Avalia o próximo ponto da trajetória 19. $i \leftarrow i + 1$ 20. próximo $\leftarrow i + 1$ 21. Fim Se 22. Fim Repete 23. $Subt \leftarrow \{dist, ini\}$ 24. Retorna $Subt$ 25. Fim
--

FIGURA 4.2 - Pseudocódigo para identificar a subtrajetória que vai em direção ao alvo.

A Figura 4.3 exemplifica a identificação da subtrajetória direcionada ao alvo. Os exemplos (A), (B) e (C) mostram a mesma trajetória $t1$ e a semirreta utilizada para testar a interseção com o objeto-alvo a cada ciclo do algoritmo. Em (A), a semirreta é criada a partir dos dois primeiros pontos dentro da região de interesse, $p2$ e $p3$. Como ela

intercepta o objeto-alvo, o ponto p2 é mantido e o teste prossegue com a semirreta entre o ponto p2 e o ponto p4, conforme imagem (B), onde novamente há interseção. No ciclo seguinte, em (C), o teste é efetuado entre os pontos p2 e p5, onde a semirreta expandida não intercepta o objeto-alvo. O processo continua com o ponto p3 como ponto inicial. Agora a semirreta expandida entre p3 e p4 intercepta o objeto-alvo, mas naquela calculada com p3 e p5 não há interseção, e assim sucessivamente.

No exemplo apresentado na Figura 4.3 somente a porção da trajetória entre p2 e p4 está indo na direção ao objeto-alvo. Assim o algoritmo retorna a distância euclidiana entre p2 e p4 como sendo a maior distância percorrida por t1 em direção ao alvo, dentro da região de interesse.

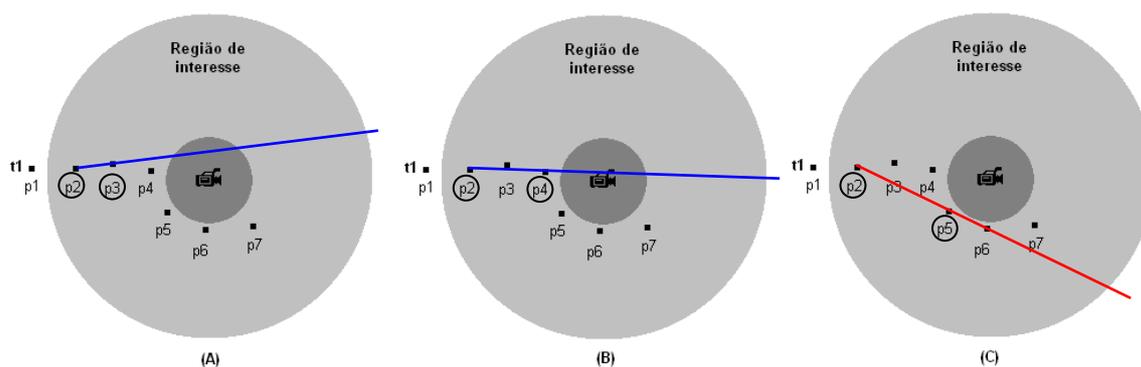


FIGURA 4.3 – Exemplo da identificação da subtrajetória em direção ao alvo

Com relação ao método criado para identificar a maior subtrajetória em direção ao alvo, cabem duas reflexões:

- i. A distância euclidiana entre os pontos inicial e final da subtrajetória direcionada ao alvo não é, por óbvio, igual à soma das distâncias entre cada ponto, salvo se houver somente dois pontos determinando essa subtrajetória ou na rara ocorrência de uma seqüência de pontos exatamente alinhados. No exemplo da Figura 4.3, a distância entre p2 e p4 é ligeiramente menor que a soma das distâncias entre p2-p3 e p3-p4. A opção por se usar a distância entre o primeiro e o último ponto no lugar da soma das distâncias se deve à simplicidade e a robustez em detrimento da exatidão. Observou-se nos experimentos que o erro gerado pela utilização deste método não afetava a correta identificação da subtrajetória direcionada ao alvo, além de tornar o algoritmo menos susceptível a falhas ocasionadas por erro ou imprecisão nos dados das trajetórias.
- ii. Num primeiro instante parece mais correto que o algoritmo identifique a mudança de direção da trajetória avaliando o comportamento da trajetória a cada ponto em relação ao seguinte. Porém, novamente aqui, tal opção tornaria o algoritmo muito sensível a falhas e imprecisão nos dados, pois uma pequena variação do ângulo entre os pontos poderia indicar erroneamente que o objeto móvel não está mais indo na direção do objeto-alvo. Assim, dificilmente poderíamos obter o comprimento da maior subtrajetória em direção ao alvo se avaliássemos somente o comportamento entre pontos consecutivos.

A Figura 4.4 ilustra essa discussão. Nesta imagem é possível observar que a trajetória $t1$ possui uma grande quantidade de pontos dentro da região de interesse posicionados em formato irregular. Nesse exemplo, a subtrajetória em direção ao alvo será calculada pelo algoritmo proposto como sendo a reta partindo do ponto $p2$ até o ponto $p14$ - imagem (A), linha verde.

Intuitivamente, a distância entre $p2$ e $p14$ é mais fiel a uma distância percorrida por $t1$ em direção ao objeto-alvo do que a soma das distâncias entre $p2$ e $p14$, ponto a ponto.

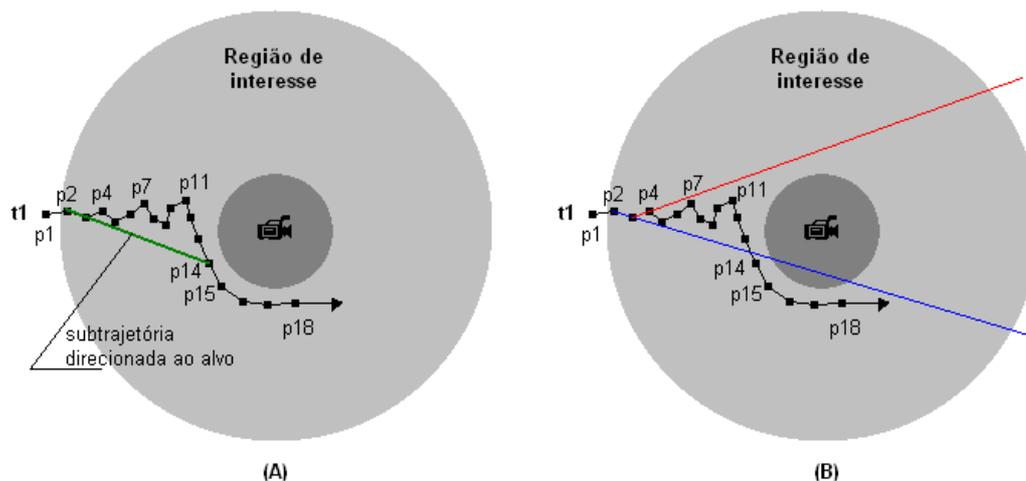


FIGURA 4.4 – Exemplo de identificação da subtrajetória em direção ao alvo quando da ocorrência de trajetória com muitos pontos dentro da região de interesse.

Ainda com relação à Figura 4.4, o exemplo (B) ilustra o porquê da opção por manter a origem da semirreta de teste de interseção no primeiro ponto onde a subtrajetória foi identificada e não avaliar seu comportamento a cada ponto. Pela imagem é possível notar que a semirreta em azul, criada no passo inicial do algoritmo entre $p2$ e $p3$, irá interceptar o objeto-alvo indicando que $t1$ está em direção ao objeto-alvo. Porém, se no próximo passo for considerado o ângulo entre $p3$ e $p4$ em vez de manter $p2$ como originalmente concebido, a semirreta calculada, em vermelho, não irá interceptar o objeto-alvo, significando que o objeto móvel não está mais indo na direção do objeto-alvo, o que, como se observa pela continuação dos pontos, não representa o real comportamento de $t1$.

O algoritmo garante que a maior porção de trajetória que vai na direção do objeto-alvo seja informada como a subtrajetória em direção ao alvo. Isso é importante porque, se a região de interesse for grande o suficiente, podem ocorrer situações em que o objeto móvel se desloca mais de uma vez em direção ao objeto-alvo antes de evitá-lo em definitivo.

Um exemplo dessa ocorrência é mostrado na Figura 4.5. Enquanto que em (A) a trajetória $t1$ se mantém na direção do objeto alvo desde o primeiro ponto dentro da região de interesse até o ponto em que é detectado o *avoidance* em $p4$, em (B) a trajetória $t2$ apresenta em dois instantes de tempo subtrajetórias que vão na direção ao objeto alvo. A primeira ocorrência é entre os pontos $p2$ e $p3$ e a segunda ocorrência é entre os pontos $p4$ e $p6$. Como maior subtrajetória em direção ao alvo o trecho de $t2$ entre $p4$ e $p6$ é o

retornado pelo algoritmo, assim como o ponto p_4 é informado como ponto inicial da subtrajetória. Esse dado será importante para o cálculo da região de incremento de confiança, conforme explicado a seguir.

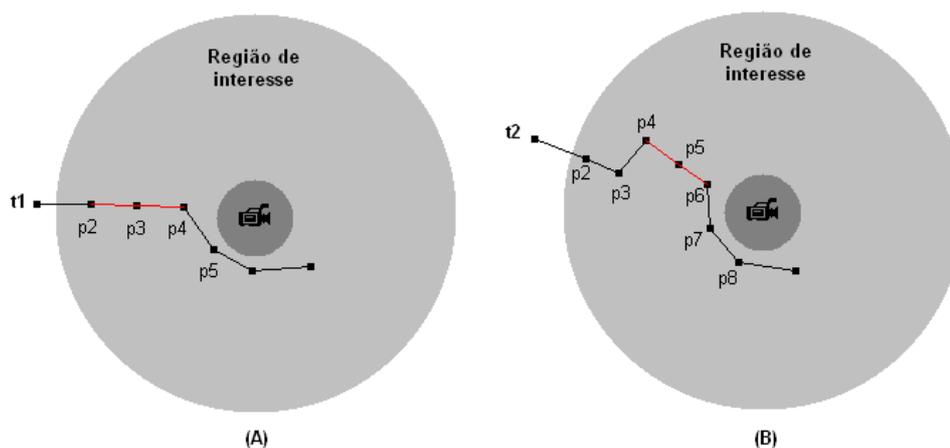


FIGURA 4.5 – Exemplo de ocorrências de subtrajetórias direcionadas ao alvo.

4.3 Pseudocódigo para geração da região de incremento de confiança

A região de incremento de confiança é responsável pela qualificação do *avoidance* encontrado como sendo *strong* ou *weak*. O objetivo principal dessa região é ser uma área de teste de interseção onde seja possível verificar se a trajetória retoma seu caminho original após evitar o objeto-alvo apresentando, com isso, um comportamento mais explícito de que seu desvio foi no intuito de evitar aquela região específica (objeto-alvo).

Para ser possível este teste, a região deve estar posicionada em um local de maior probabilidade de retomada do caminho original da trajetória o que, pela nossa interpretação, está situado entre o objeto alvo e a borda da região de interesse, do lado oposto ao ponto inicial da subtrajetória direcionada ao alvo, conforme Definição 6.

A Figura 4.6 apresenta o pseudocódigo para o cálculo da região de incremento de confiança.

O primeiro passo é obter o centro geométrico do objeto-alvo (linha 2) para então se calcular o ângulo de inclinação entre o ponto inicial da subtrajetória direcionada ao alvo e o centro do objeto-alvo (linha 3). Esse ângulo irá corresponder à inclinação da região de incremento de confiança.

A largura da região de incremento de confiança será dada por duas retas tangenciais ao objeto-alvo, calculadas nas linhas 4 e 5. As retas serão criadas partindo de dois pontos extremos, tangentes ao objeto-alvo, em direção à borda da região de interesse no lado oposto ao ponto inicial da subtrajetória direcionada ao alvo, com a mesma inclinação calculada na linha 3.

Por fim, é obtida a região delimitada pelas retas tangenciais criadas, pela borda do objeto-alvo e pela borda da região de interesse (linha 6). Essa região é informada como sendo a região de incremento de confiança dessa trajetória em relação a este objeto-alvo.

<p>Entrada: <i>o</i> //objeto alvo <i>d</i> // tamanho do buffer da região de interesse <i>ini</i> // ponto inicial da subtrajetória direcionada ao alvo</p> <p>Saída: <i>reg</i> // região de incremento de confiança</p> <p>Método: RegIncrConf()</p> <ol style="list-style-type: none"> 1.início 2. <i>Oc</i> ← centroid(<i>o</i>) // centro geométrico de <i>o</i> 3. <i>az</i> ← azimuth(<i>ini</i>, <i>Oc</i>) // Obtém inclinação da região de incremento de confiança 4. <i>lim1</i> ← makeline1 (<i>az</i>, <i>o</i>, exteriorring(buffer(<i>o</i>, <i>d</i>))) 5. <i>lim2</i> ← makeline2 (<i>az</i>, <i>o</i>, exteriorring(buffer(<i>o</i>, <i>d</i>))) 6. <i>reg</i> ← CalculaRegião(<i>lim1</i>, exteriorring(<i>o</i>), <i>lim2</i>, exteriorring(buffer(<i>o</i>, <i>d</i>))) // calcula região dentro dos limites informados 7. retorna <i>reg</i> // devolve a região de incremento de confiança 8.Fim
--

FIGURA 4.6 – Pseudocódigo da função que gera a região de incremento de confiança

A Figura 4.7 exemplifica a construção de uma região de incremento de confiança para objeto-alvo não circular. Em (A) a trajetória *t1* intercepta a região de interesse do objeto-alvo *o1* correspondente a uma geometria não circular, realizando o *avoidance*. Em (B) é mostrada a linha que liga o primeiro ponto da subtrajetória direcionada ao alvo e o centro geométrico do objeto-alvo² (ponto vermelho). Na imagem (C) é possível visualizar as duas linhas paralelas e tangenciais ao objeto-alvo que delimitarão a região a ser criada. Essas linhas acompanham a inclinação da linha gerada em (B). Em (D) a imagem da região de incremento de confiança gerada para *t1* em relação ao objeto-alvo *o1*.

Optou-se por utilizar o ponto inicial da subtrajetória direcionada ao alvo para determinar a posição e inclinação da região de incremento de confiança por se tratar do deslocamento de maior referência desta trajetória dentro da região de interesse. Se outro ponto fosse utilizado, a posição e a inclinação desta região mudaria, conforme exemplo da Figura 4.8. Na imagem (A) é possível visualizar a região de incremento de confiança se fosse criada tendo por referência o primeiro ponto da trajetória dentro da região de interesse. A linha em azul determina a inclinação da região a ser criada. Já em (B), a subtrajetória direcionada ao alvo (linha em vermelho) indica qual o ponto que deve ser utilizado para a criação da região de incremento de confiança nesse objeto-alvo, neste caso o ponto *p4*.

Neste exemplo, a uso do primeiro ponto da subtrajetória direcionada ao alvo fez a diferença entre um *weak avoidance* (A) e um *strong avoidance* (B), já que em (B) ocorre

² A posição, nesse exemplo, é baseada de um valor empírico. Uma função matemática é necessária para a definição do ponto exato do centro geométrico.

a interseção da trajetória t1 com a região de incremento de confiança (círculo em destaque).

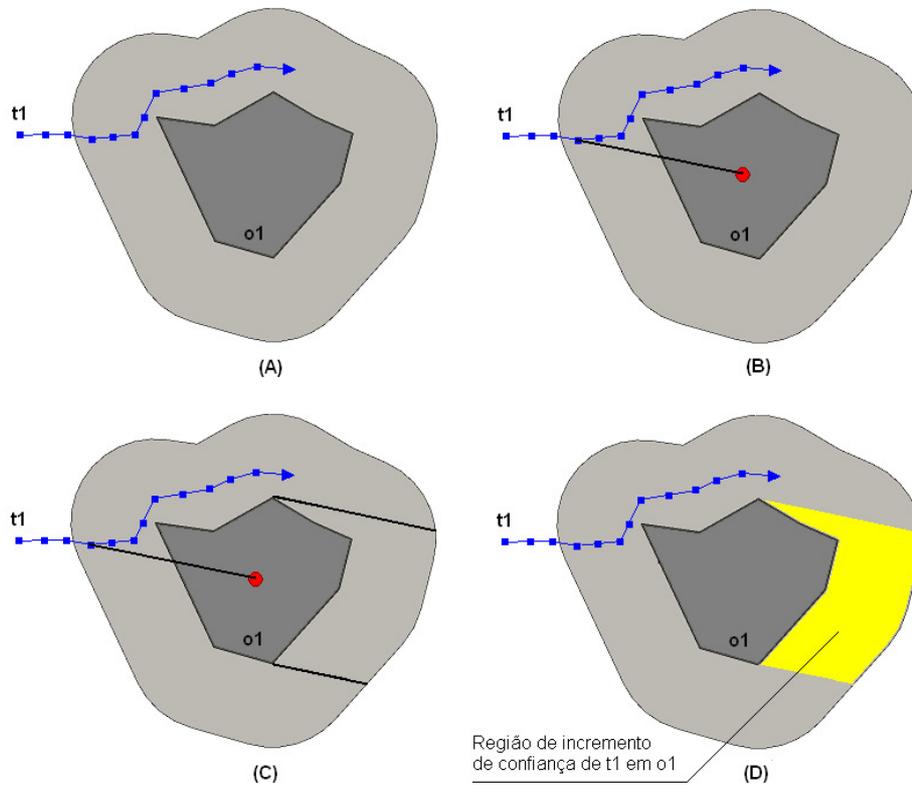


FIGURA 4.7 – Exemplo de região de incremento de confiança para objeto-alvo não circular.

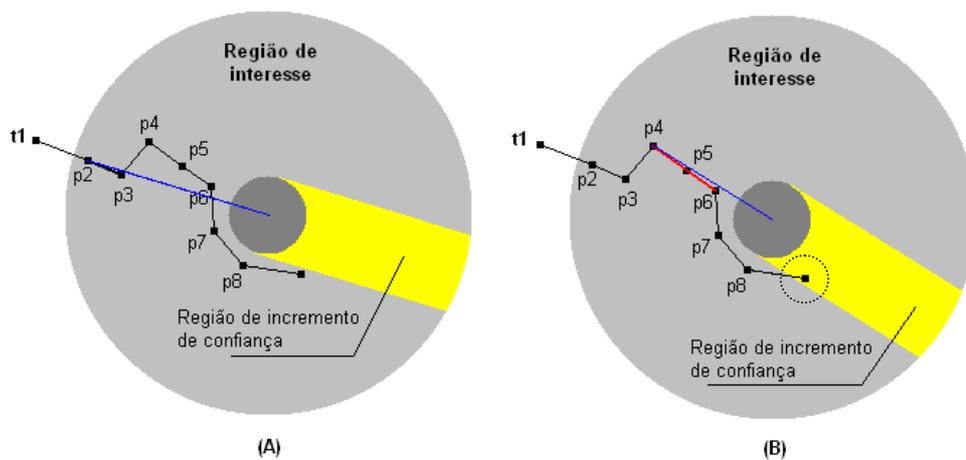


FIGURA 4.8 – Exemplo da interferência do ponto inicial da subtrajetória direcionada ao alvo na criação da região de incremento de confiança.

5 Experimentos e resultados

Para verificar a eficácia do algoritmo foram realizados experimentos com diferentes conjuntos de trajetórias de objetos móveis. Estas trajetórias foram capturadas ora sem qualquer restrição, ora com a determinação de evitarem algumas regiões específicas, mapeadas como objetos-alvo. Os pontos das trajetórias foram obtidos por aparelhos GPS ajustados para capturar um ponto a cada segundo.

Os dados das trajetórias e dos objetos-alvo foram armazenados em tabelas no SGBD PostgreSQL com a extensão PostGis. O algoritmo foi codificado em Java com o uso da IDE NetBeans.

Embora o objeto-alvo possa ser qualquer geometria convexa, optamos neste trabalho pelo uso de um ponto envolto por um *buffer* por questão de simplificação. Deve-se a isso o fato de que todas as imagens dos experimentos mostradas nesse capítulo são compostas de regiões circulares.

Para os testes, dois grupos de trajetórias de veículos foram obtidos em diferentes cidades e com características distintas. Um terceiro grupo de trajetórias, obtido por pedestres caminhando em um parque na cidade de Porto Alegre, também foi utilizado nos experimentos. No final deste capítulo são apresentados gráficos que permitem a comparação visual entre alguns parâmetros informados e os resultados obtidos em cada grupo de dados.

O tamanho mínimo da subtrajetória direcionada ao alvo foi ajustado para ser 10% da diferença entre os raios do objeto-alvo e do *buffer* da região de interesse. Por exemplo: um experimento realizado utilizando-se objetos-alvo com 20m de raio, com um *buffer* de 100m para região de interesse, resultaria em uma subtrajetória direcionada ao alvo mínima de 8m. Tal percentual foi obtido por experimentação e mostrou-se adequado para os diferentes tipos de trajetórias utilizadas nesta dissertação.

5.1 Experimento 1 - trajetórias de veículos em Porto Alegre - RS

O primeiro grupo utilizado nos experimentos é composto por 21 trajetórias, aproximadamente 3,1 mil pontos, obtidas a partir de veículos trafegando em ruas e avenidas de Porto Alegre onde foram definidas quatro regiões de monitoramento mapeadas como objetos-alvo. Neste primeiro grupo as trajetórias são curtas e com rotas calculadas previamente para realizar a experimentação do algoritmo com casos críticos, de modo a verificar a eficácia do mesmo.

Na Figura 5.1 é possível ver, com auxílio do *Google Maps*, a distribuição das trajetórias – linhas em azul – e dos objetos-alvo – círculo em vermelho - utilizados neste experimento. Por esta imagem se observa que os objetos-alvo 0, 1 e 2 possuem pelo menos uma trajetória que o intercepta, enquanto que nenhuma trajetória cruza pela região do objeto-alvo 3. Assim o fator de ponderação calculado pelo algoritmo para os objetos-alvo 0, 1 e 2 foi 1,0 e o fator calculado para o objeto-alvo 3 foi 0,5.



FIGURA 5.1 – Visualização no *Google Maps* das trajetórias obtidas por veículos na cidade de Porto Alegre

Na definição do tamanho do objeto-alvo e do *buffer* da região de interesse foi levado em consideração a largura das ruas e o tamanho médio das quadras onde os veículos trafegaram. Desta forma, foi utilizado 20m como raio do objeto-alvo e 100m como *buffer* da região de interesse. Como tamanho mínimo da subtrajetória direcionada ao alvo foi utilizado o valor de 8m.

Dois experimentos foram realizados com esse conjunto de trajetórias. No primeiro experimento não foi utilizada a tabela de eventos, assim todas as ocorrências de *avoidance* identificadas foram computadas no cálculo da confiança global.

A Figura 5.2 apresenta a saída em tela ao final da execução do algoritmo com as trajetórias que tiveram um *avoidance* detectado e seus respectivos graus de confiança global. Os altos índices de percentual de *avoidance* por região de interesse são explicados pela natureza dos dados, uma vez que a intenção era exatamente realizar o padrão comportamental aqui descrito como forma de testar o algoritmo.

A Figura 5.3 mostra, individualmente, o comportamento das trajetórias que tiveram *avoidance* detectado neste experimento. Nesta imagem o objeto-alvo está representado por um círculo vermelho com a região de interesse ao redor, em amarelo. A região de incremento de confiança está representada pela área em cinza claro. O sentido da trajetória está informado por uma seta.

Dados de avoidance por região de interesse:	
GID	Percentual
0	50%
1	57.14%
2	50%
3	50%

Cálculo da confiança global do avoidance:	
TID	Confiança Global
7	1
13	1
18	0.93
21	0.5
15	0.4
11	0.25

FIGURA 5.2 – Resultado em tela após a execução do algoritmo para os dados de trajetória de veículos em Porto Alegre sem uso da tabela de eventos.

As trajetórias 7 e 13 evitaram uma única região de interesse cada uma, interceptando a região de incremento de confiança, de modo que obtiveram grau 1 de confiança global. As trajetórias 18, 21 e 15 percorrem uma distância maior interceptando mais de uma região de interesse, com comportamentos distintos em cada caso.

A trajetória 18 intercepta as quatro regiões de interesse, sendo que nos objetos-alvo 0, 1 e 2 intercepta também a região de incremento de confiança, recebendo valor *strong* como confiança local nestes casos. No objeto-alvo 3 a trajetória recebe *weak* como confiança local, já que não intercepta a região de incremento de confiança após evitar o objeto-alvo.

Na trajetória 21, três regiões de interesse são interceptadas, todas com valor de confiança local *weak*, já que não houve interseção com a região de incremento de confiança de nenhum dos objetos-alvo. A interseção da trajetória 21 com a região de incremento de confiança no objeto-alvo 1 não caracteriza um valor de *strong* para confiança local pois a interseção se dá em um tempo anterior à ocorrência do *avoidance*.

A trajetória 15 apresenta uma situação de *avoidance* com grau *strong* quando intercepta a região de interesse do objeto-alvo 0. Em relação ao objeto-alvo 1, a trajetória recebe grau confiança local *none* pois intercepta este objeto-alvo. O valor de *none* também é atribuído em relação ao objeto-alvo 3 pois a trajetória intercepta a região de interesse e não apresenta uma subtrajetória direcionada ao alvo.

Por fim, a trajetória 11 apresentou um *avoidance* com relação ao objeto-alvo 1, porém não retomou o trajeto original, de modo que não intercepta a região de incremento de confiança. Neste caso um valor de *weak* será atribuído para confiança local. A trajetória intercepta também a região de interesse do objeto-alvo 0 sem, entretanto, apresentar uma subtrajetória direcionada ao alvo, neste caso não sendo considerado um *avoidance*.

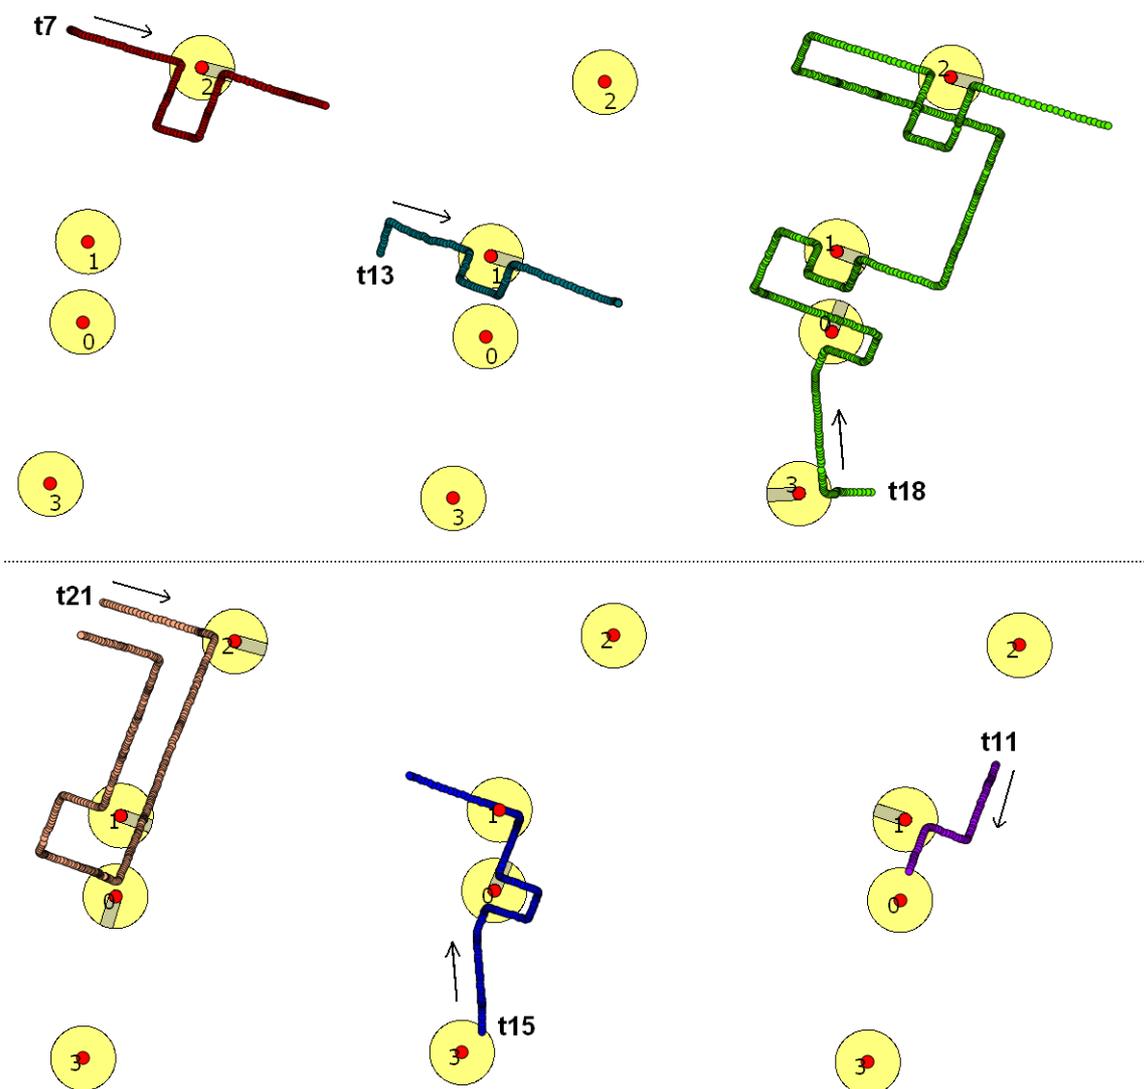


FIGURA 5.3 – Trajetórias obtidas por veículos em Porto Alegre, com as ocorrências de *avoidance* detectadas pelo algoritmo.

Neste experimento, o tempo médio de execução do algoritmo para o conjunto de dados e parâmetros informados foi de 4791 ms³.

Um segundo experimento com este mesmo grupo de trajetórias foi executado, desta vez fazendo uso da tabela de eventos para testar o procedimento responsável por minimizar as falsas ocorrências de *avoidance*.

Neste novo experimento foram informadas três ocorrências de eventos em regiões de *avoidance* conhecido, conforme mostra a Tabela 5.1.

³ Média aritmética do tempo de três execuções para o mesmo grupo de dados, com os mesmos parâmetros.

TABELA 5.1 – Eventos informados para teste dos dados de veículos em Porto Alegre.

Gid	evento	início	fim	the_geom
0	Feira de rua	2010-09-05 08:00:00	2010-09-05 15:30:00	POINT(...)
1	Pavimentação	2010-09-05 10:00:00	2010-09-05 13:30:00	POINT(...)
2	Manutenção rede de água	2010-08-20 10:15:00	2010-08-21 22:30:00	POINT(...)

O evento denominado ‘Feira de rua’ foi localizado na mesma posição geográfica do objeto alvo 0 e seu período de duração coincide com as trajetórias 18 e 21, as quais realizaram *avoidance* neste objeto alvo. Os eventos ‘Pavimentação’ e ‘Manutenção rede de água’ foram localizados na região do objeto-alvo 2, com períodos de existência distintos, como pode ser observado na Tabela 5.1.

O algoritmo corretamente relacionou os eventos que impediam o fluxo normal de trajetórias nas regiões informadas e desconsiderou as ocorrências de *avoidance* naqueles objetos-alvo dentro do período de duração dos eventos.

Na Figura 5.4 está a saída em tela após execução do algoritmo onde é possível observar as ocorrências desconsideradas.

Avoidances desconsiderados pela referência a eventos:			
Tid	Gid	Obj.Alvo	Evento
18	0		Feira de rua
18	2		Pavimentação
21	0		Feira de rua
Dados de avoidance por região de interesse:			
	GID	Percentual	
	0	25%	
	1	57.14%	
	2	40%	
	3	50%	
Cálculo da confiança global do avoidance:			
	TID	Confiança Global	
	7	1	
	13	1	
	18	0.83	
	21	0.5	
	15	0.4	
	11	0.25	

FIGURA 5.4– Resultado em tela após a execução do algoritmo para os dados de trajetória de veículos em Porto Alegre com uso da tabela eventos.

Sem o uso da tabela de eventos, a confiança global da trajetória 18 é o resultado do seguinte cálculo, conforme Definição 10:

$$Av_{18} = \frac{0,5 \cdot 0,5 + 1 \cdot 1 + 1 \cdot 1 + 1 \cdot 1}{0,5 + 1 + 1 + 1} = \frac{3,25}{3,5} = 0,928$$

Como as ocorrências de *avoidance* nos objetos-alvo 0 e 2 foram excluídas da análise devido à informação da tabela de eventos, a confiança global dessa trajetória é resultado do cálculo:

$$Av_{r18} = \frac{0,5 \cdot 0,5 + 1 \cdot 1}{0,5 + 1} = \frac{1,25}{1,5} = 0,833$$

O mesmo raciocínio é utilizado no cálculo da confiança global da trajetória 21, cujo valor de *avoidance* global não se alterou porque os três *avoidances* locais eram do mesmo tipo *weak*.

O *avoidance* identificado para a trajetória 15 no objeto alvo 0 ainda permanece pois o seu *timestamp* não coincide com o tempo de duração do evento informado. Tal situação foi corretamente identificada pelo algoritmo.

O evento ‘Manutenção rede de água’ foi propositadamente inserido em um *timestamp* onde não houvesse nenhuma interseção temporal com os dados das trajetórias que realizaram *avoidance* neste objeto alvo. O objetivo disso é verificar se o algoritmo só irá desconsiderar ocorrências de *avoidance* quando houver interseção tanto espacial quanto temporal do evento com o *avoidance* identificado. De fato, como se observa na Figura 5.4, nenhuma ocorrência de *avoidance* relacionada ao evento ‘Manutenção rede de água’, foi desconsiderada.

Com a inserção da tabela de eventos na análise do algoritmo, o tempo médio de execução aumentou para 5442 ms⁴.

5.2 Experimento 2 - trajetórias de veículos em Xangri-lá - RS

O segundo grupo de trajetórias de veículos utilizadas nos experimentos foi obtido por diferentes indivíduos trafegando em ruas e avenidas na cidade de Xangri-lá, próximo à Capão da Canoa. Essas trajetórias diferem das obtidas em Porto Alegre por serem mais extensas e por serem capturadas sem qualquer orientação prévia quanto ao comportamento do condutor. A Figura 5.5 mostra parte das trajetórias obtidas e a localização dos objetos-alvo informados neste experimento (círculo em vermelho).

O objetivo desse segundo experimento com trajetórias de veículos é testar a eficiência do algoritmo, submetendo-o a um grupo maior de dados e medindo o tempo de execução para comparação com o tempo de execução obtido com os dados de Porto Alegre.

Esse grupo de dados é composto de 41 trajetórias que totalizam aproximadamente 19,8 mil pontos. Os 10 objetos-alvo informados foram posicionados em cruzamentos e avenidas movimentadas onde havia algum elemento relevante (lojas ou centro de compras, cruzamento de avenidas, área de importância econômica, entre outros)

Neste experimento foi considerado o objeto-alvo com 20m e 120m para o *buffer* da região de interesse, devido ao tamanho médio das quadras ser um pouco maior que os

⁴ Média aritmética do tempo de três execuções para o mesmo grupo de dados, com os mesmos parâmetros.

de Porto Alegre. Para o tamanho mínimo da subtrajetória direcionada ao alvo foi informado 10m.

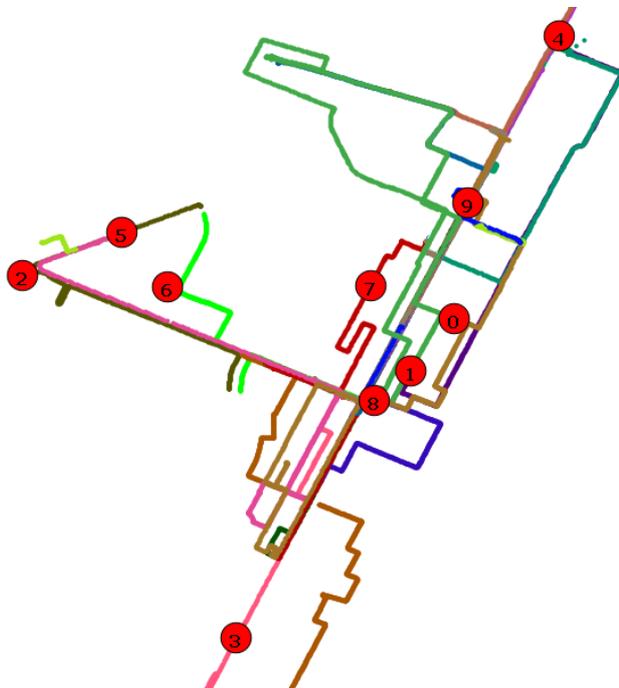


FIGURA 5.5 – Exemplo de trajetórias obtidas por veículos trafegando na cidade de Xangri-lá e objetos-alvo informados no experimento 2.

A Figura 5.6 apresenta a saída em tela após a execução do algoritmo para este grupo de dados. Nesta imagem observa-se que os objetos-alvo 0 e 6 tiveram um índice de 100% de *avoidance*, calculado de acordo com a fórmula da Definição 8. Seguindo a heurística e o algoritmo mostrados nos capítulos anteriores, estes objetos-alvo foram desconsiderados e as ocorrências de *avoidance* detectadas em relação a estes objetos-alvo deixaram de existir, não afetando o cálculo da confiança global.

Visualizando as trajetórias que interceptam a região de interesse do objeto-alvo 0, identificamos que as ocorrências de *avoidance* detectadas pelo algoritmo são relacionadas às trajetórias 28 e 33. A Figura 5.7 mostra o comportamento dessas trajetórias em relação ao objeto-alvo 0. Nesta imagem é possível ver que nenhuma outra trajetória intercepta a região de interesse do objeto-alvo 0, de modo que seu percentual de *avoidance* foi corretamente calculado em 100%.

Com o aumento na quantidade de pontos de trajetórias e de objetos-alvo, houve uma elevação no tempo médio de execução do algoritmo. Para os dados de Xangri-lá o tempo médio de execução ficou em 39116 ms⁵.

⁵ Média aritmética do tempo de três execuções para o mesmo grupo de dados, com os mesmos parâmetros.

Dados de avoidance por região de interesse:

	GID	Percentual
*	0	100%
	1	33.34%
	2	50%
	3	0%
	4	40%
	5	0%
*	6	100%
	7	0%
	8	33.34%
	9	9.09%

Objetos-alvo marcados com * serão removidos do cálculo do índice de confiança global.

Cálculo da confiança global do avoidance:

TID	Confiança Global
12	1
33	0.75
9	0.667
17	0.5
19	0.5
20	0.5
29	0.5
7	0.25
21	0.25
2	0.167

FIGURA 5.6 - Resultado em tela após a execução do algoritmo para os dados de trajetória de veículos em Xangri-lá.

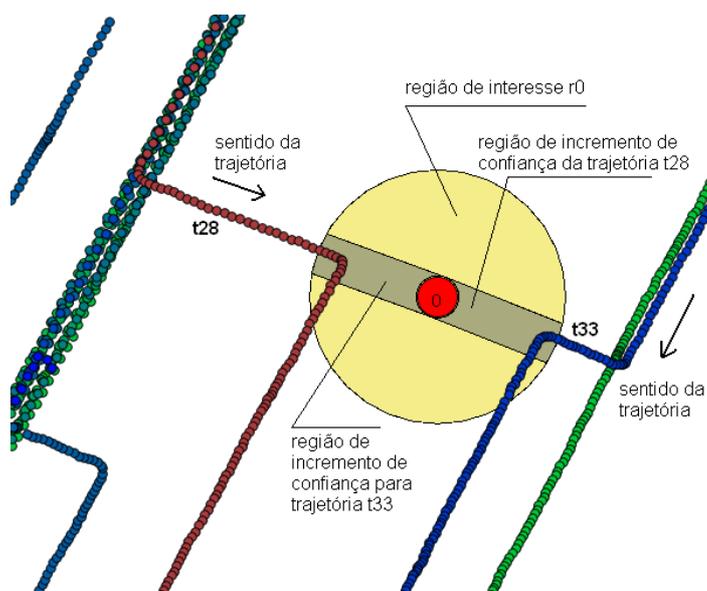


FIGURA 5.7 – Avoidances detectados no objeto-alvo 0 para trajetórias de veículos capturadas na cidade de Xangri-lá.

5.3 Experimento 3 - trajetórias obtidas por pedestres em parque público

Um outro grupo de dados utilizados nos experimentos é composto de trajetórias coletadas por pedestres caminhando em um parque na cidade de Porto Alegre. Para este experimento as trajetórias foram obtidas por três pessoas diferentes, com a orientação de ora transitar normalmente, ora evitar determinadas regiões marcadas como sendo objetos-alvo.

Diferente das trajetórias obtidas por veículo que devem seguir uma malha viária, trajetórias de pedestres pode seguir em qualquer direção pois, embora existam caminhos pavimentados no parque, o pedestre poderia optar por outra rota qualquer fazendo com que essas trajetórias apresentem características bem distintas do primeiro grupo obtido por veículos. Outro fator importante a ser levado em consideração é a velocidade com que o objeto móvel se desloca, pois afeta a densidade e a distribuição dos pontos das trajetórias. Um pedestre caminhando por 15 minutos apresenta um deslocamento bem inferior a um veículo trafegando em uma via expressa no mesmo tempo. Sendo que o aparelho de captura de trajetórias estava configurado em nossos experimentos para obter um ponto por segundo, em 15 minutos os pontos obtidos por um pedestre estarão bem mais concentrados que aqueles obtidos pelo veículo no mesmo intervalo de tempo. Tal diversidade no comportamento e no formato dos dados motivou a realização de experimentos também neste grupo de trajetórias de objetos móveis.

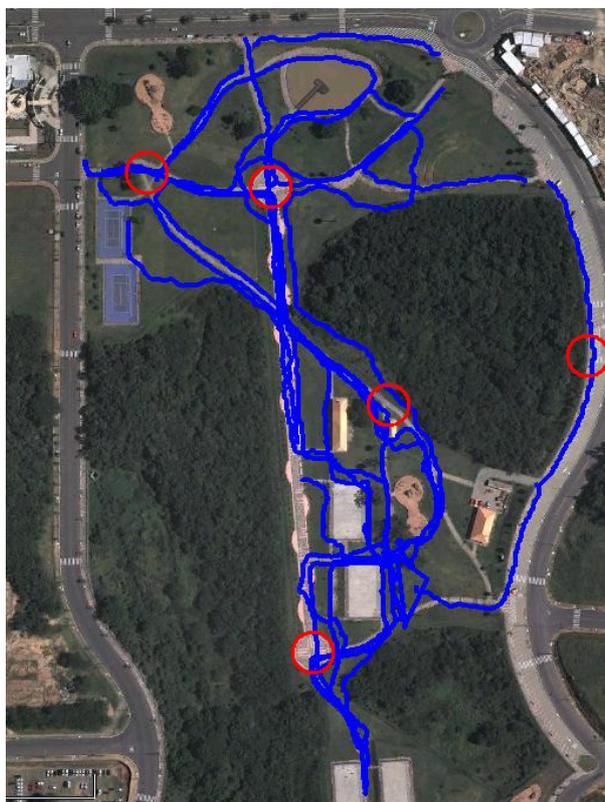


FIGURA 5.8 – Trajetórias de pedestres no parque Germânia em Porto Alegre visualizadas no *Google Earth*.

Para este experimento foram coletadas 17 trajetórias, totalizando aproximadamente 5,5 mil pontos. Tais trajetórias foram obtidas no parque Germânia na

cidade de Porto Alegre onde foram definidas cinco regiões de monitoramento nos cruzamentos e em algumas vias de circulação pavimentadas, com uma área de 10m de raio. Para este grupo de trajetórias utilizou-se 50m como *buffer* da região de interesse simulando a distância razoável para um pedestre identificar um vigilante ou uma câmera e, então, optar por mudar ou não de trajeto. Como subtrajetória direcionada ao alvo o valor utilizado foi 4m.

A Figura 5.8 mostra a visualização no *Google Earth* das trajetórias coletadas no parque Germânia. Os círculos em vermelho identificam as regiões de monitoramento definidas como objetos-alvo.

Neste experimento, quatro trajetórias tiveram *avoidances* detectados pelo algoritmo como mostra a Figura 5.9. Todos os objetos-alvo foram interceptados por pelo menos uma trajetória em algum instante de tempo, assim receberam grau 1 como fator de ponderação.

Dados de avoidance por Região de Interesse:	
GID	Percentual
0	11.111%
1	14.286%
2	33.33%
3	37.5%
4	0%
Cálculo da confiança global do avoidance:	
TID	Confiança Global
7	0.667
6	0.5
8	0.5
4	0.167

FIGURA 5.9 - Resultado em tela após a execução do algoritmo para os dados de trajetória de pedestres no parque Germânia, em Porto Alegre.

A Figura 5.10 mostra as trajetórias que tiveram *avoidances* identificados. Novamente aqui o objeto-alvo é mostrado em vermelho no centro da região de interesse representada pelo círculo em amarelo e em cinza as regiões de incremento de confiança da trajetória em relação ao objeto-alvo em questão. As setas indicam o sentido da trajetória.

A trajetória 7 obteve o maior índice de confiança global. De acordo com os parâmetros informados a trajetória evitou os objetos-alvo 1 e 2 com confiança local *strong*. A confiança global foi reduzida pela interseção desta trajetória com a região de interesse do objeto-alvo 0, onde não apresentou uma subtrajetória direcionada ao alvo. Experimentos adicionais demonstraram que quando informado um valor de 2m para o tamanho mínimo da subtrajetória direcionada ao alvo, o *avoidance* é identificado neste objeto-alvo e o valor da confiança global passa a ser máximo para a trajetória 7.

A trajetória 6 realizou *avoidance* no objeto-alvo 2, onde recebeu *strong* como confiança local, pois interceptou a região de incremento de confiança. No objeto-alvo 3, foi identificado o *avoidance* com grau de confiança local *weak*. Como essa trajetória interceptou a região de interesse do objeto-alvo 0 sem ter uma trajetória direcionada ao alvo, recebeu *none* de confiança local neste objeto-alvo.

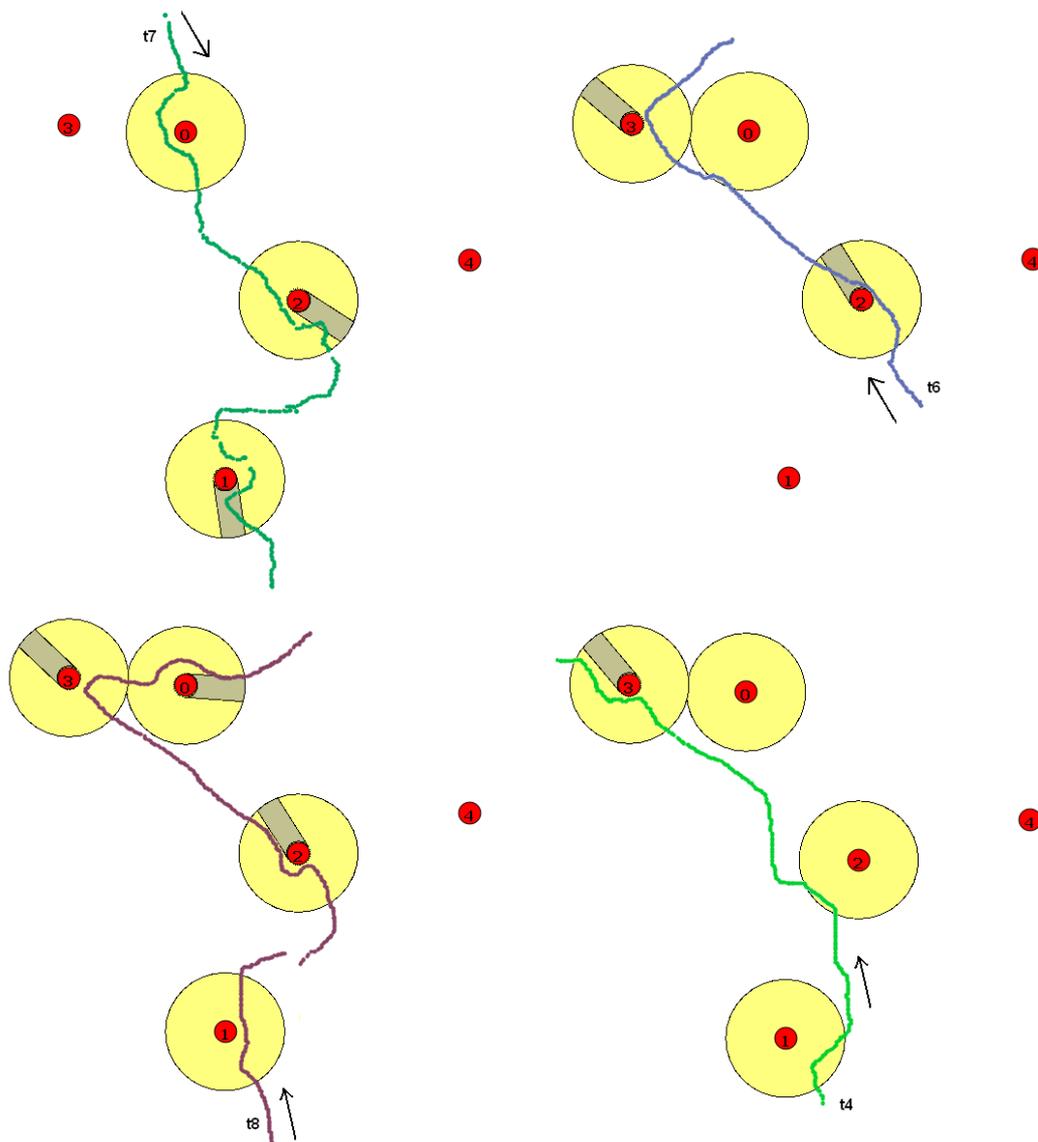


FIGURA 5.10 - Trajetórias obtidas por pedestres no Parque Germânia com ocorrências de *avoidance* detectadas.

A trajetória 8 intercepta 4 regiões de interesse, sendo que nos objetos-alvo 2 e 3 a trajetória não interceptou a região de incremento de confiança, recebendo valor *weak* como confiança local. Já no objeto-alvo 0 recebeu o valor *strong*. Com relação ao objeto-alvo 1, não há uma subtrajetória direcionada ao alvo, portanto não foi identificado *avoidance* nessa ocorrência.

Finalmente, a trajetória 4 intercepta 3 regiões de interesse, sendo que a ocorrência de *avoidance* só é identificada no objeto-alvo 3 onde recebe confiança local *weak*.

5.4 Gráficos comparativos e considerações sobre os experimentos.

No gráfico da Figura 5.11 é possível visualizar a quantidade total de pontos nas trajetórias e a quantidade de pontos dentro de alguma região de interesse, de acordo com os parâmetros informados durante a execução de cada experimento. É possível observar que a quantidade de pontos que estão dentro de alguma região de interesse é bem inferior à quantidade total de pontos existente na base de dados, inclusive no caso dos experimentos de veículos em Porto Alegre, onde foram obtidas trajetórias curtas e próximas aos objetos-alvo.

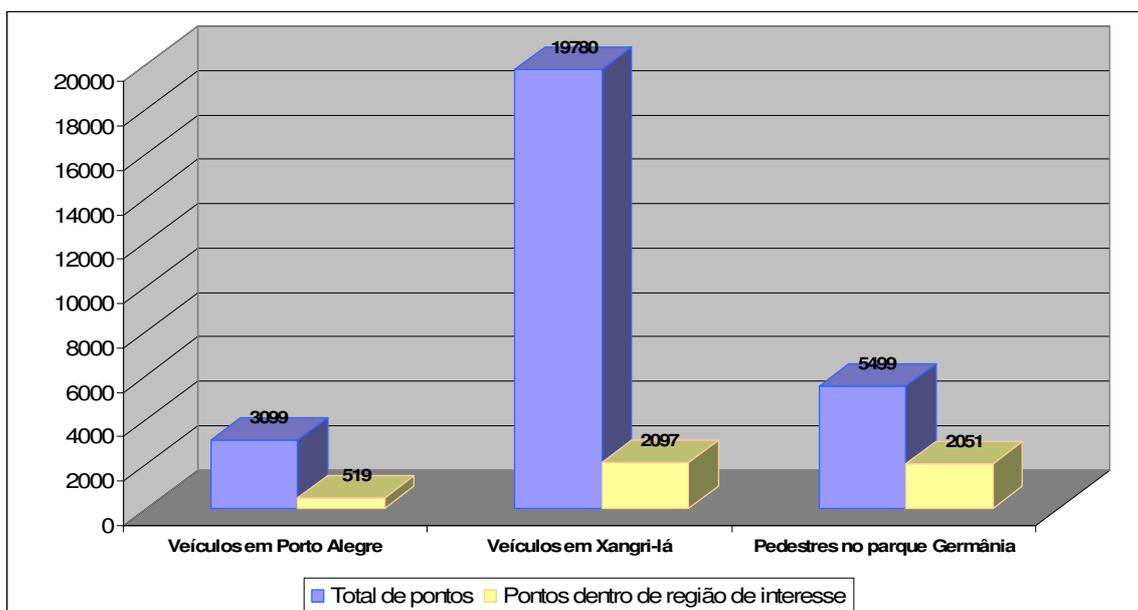


FIGURA 5.11 – Gráfico comparativo entre o número total de pontos nas trajetórias e o número de pontos dentro de alguma região de interesse.

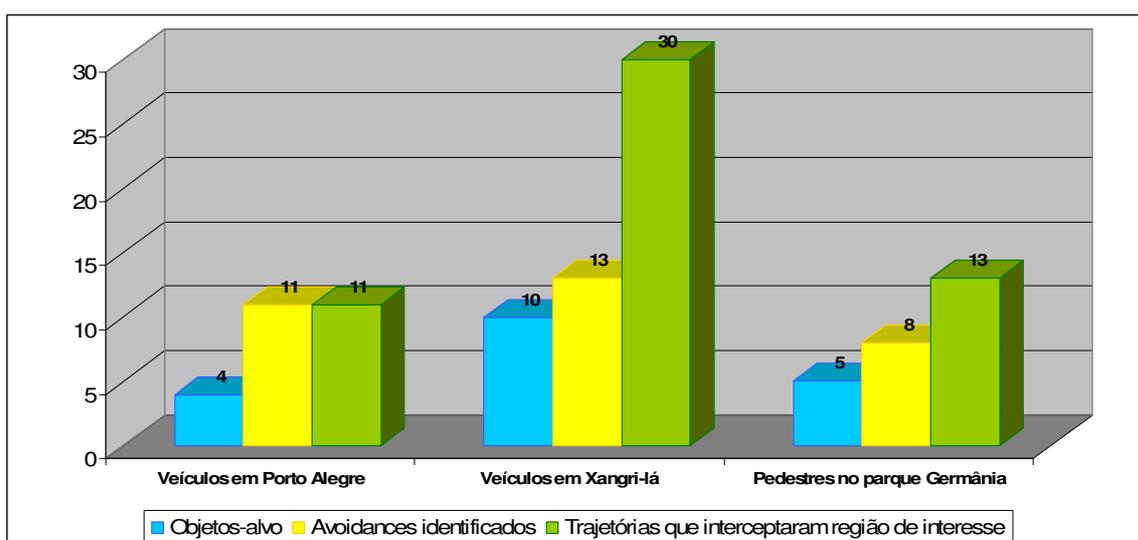


FIGURA 5.12 – Gráfico comparativo entre a quantidade de objetos-alvo, *avoidance* identificados e trajetórias que interceptaram alguma região de interesse.

Na Figura 5.12 estão relacionadas as quantidades de objetos-alvo, a quantidade de *avoidances* identificados e a quantidade de trajetórias que interceptaram alguma região de interesse.

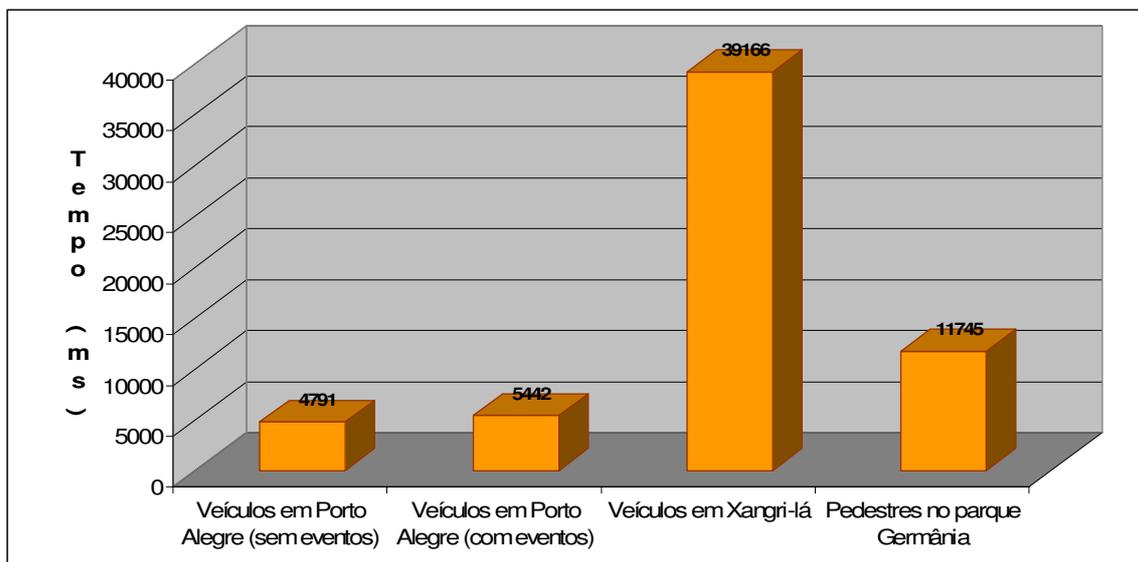


FIGURA 5.13 – Gráfico comparativo dos tempos médios de execução nos diferentes experimentos.

A Figura 5.13 apresenta o gráfico comparativo entre os tempos médios de execução do algoritmo nos experimentos realizados. Nesta imagem é possível observar que houve um pequeno aumento no tempo de execução quando informada a tabela de eventos para os experimentos com dados de veículos em Porto Alegre. Tal aumento foi considerado normal pois, informando a tabela de eventos, é submetido ao aplicativo mais uma base de dados a ser acessada e mais um teste de interseção a ser avaliado, o que demanda um maior tempo de processamento.

O tempo de execução para o experimento com trajetórias de veículos na cidade de Xangri-lá foi bem superior aos demais, como mostrado no gráfico da Figura 5.13, o que é perfeitamente compreensível, pois é o experimento com o maior número de pontos de trajetória.

6 Conclusões e trabalhos futuros

Este trabalho propõe um algoritmo para detecção de um novo padrão comportamental denominado *avoidance*, que ocorre quando objetos móveis evitam determinadas regiões espaciais. A identificação desse padrão comportamental é importante em áreas como segurança, controle de trânsito, *games*, estudo de comportamentos sociais, entre outros.

Para ser viável a identificação deste padrão comportamental, construímos uma heurística com base no estudo de caso de comportamentos de objetos móveis tanto quando seguindo uma malha viária (veículos em uma cidade) quanto aqueles com deslocamento livre (pessoas em um parque).

Durante a construção da heurística, buscou-se criar formas de validação e aumento da confiança das ocorrências identificadas, aumentando o grau de certeza nos *avoidances* encontrados. Além disso, a heurística é composta de ferramentas que permitem informar eventos conhecidos que impeçam o livre trânsito em determinada região, reduzindo as ocorrências de falso positivo.

Com base na heurística proposta foi construído um algoritmo para automatizar a identificação do padrão comportamental *avoidance* em trajetórias de objetos móveis, que posteriormente foi codificado.

Para testar sua eficácia, foram realizados experimentos com dados reais obtidos com aparelhos GPS por veículos e por pedestres na cidade de Porto Alegre e Xangri-lá e posteriormente os resultados gerados pelo algoritmo foram comparados com aqueles calculados manualmente. Para os experimentos buscou-se utilizar dados com características espaciais e comportamentais distintos para, desta forma, testar o algoritmo com diferentes situações e assim chegar a um código mais robusto e confiável.

O algoritmo desenvolvido identificou com sucesso as trajetórias que evitaram as regiões informadas como objeto-alvo, tanto nas trajetórias de pedestre quanto nas de veículos, retornando o resultado esperado de acordo com os parâmetros informados.

Parte deste trabalho foi publicado no GeoInfo 2010 (Loy. 2010) tendo sido selecionado como um dos três melhores artigos do congresso. Uma versão estendida foi aceita para publicação no *Journal* da Sociedade Brasileira de Computação (Loy. 2011).

Como trabalho futuro pretende-se:

- i. Melhorar o algoritmo proposto para evitar situações como a ocorrida na trajetória 18 da Figura 5.3. O *avoidance* desta trajetória no objeto-alvo 0 recebeu valor *strong* para confiança local. Porém, a interseção com a região de incremento de confiança foi em um sentido perpendicular, não estando, desta forma, totalmente de acordo com o que foi discutido no capítulo 3 e com a natureza da região de incremento de confiança dada pela Definição 6.
- ii. Avaliar outras técnicas para criação da região de incremento de confiança. Um algoritmo mais robusto permitiria construir diferentes formatos desta região para diferentes geometrias de objetos-alvo, permitindo uma avaliação mais precisa do grau de confiança local do *avoidance*.

- iii. O algoritmo desenvolvido considera que qualquer trajetória interceptando o objeto-alvo é suficiente para atribuir grau 1,0 ao fator de ponderação w_k . Pretende-se estudar a interferência do sentido da trajetória na atribuição do fator de ponderação w_k . O sentido da trajetória pode interferir em casos como, por exemplo, quando o objeto-alvo informado corresponder a uma câmera de vigilância localizada em uma grande avenida. Pode ocorrer que, durante o período de captura das trajetórias, as pistas em um dos sentidos estejam interrompidas. Desta forma entende-se que o fator de ponderação do sentido interrompido deva ser diferente do fator de ponderação onde o fluxo foi normal.

Também é projeto para futuro a construção de heurísticas para identificação de *avoidances* entre trajetórias de objetos móveis e a ampliação da heurística aqui apresentada para identificação de comportamentos suspeitos em trajetórias sem a informação de objetos-alvo conhecidos.

Referências Bibliográficas

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.

ANDERSSON, MATTIAS; GUDMUNDSSON JOACHIM; LAUBE, PATRICK AND WOLLE, THOMAS. **Reporting Leaders and Followers Among Trajectories of Moving Point Objects**, *Geoinformatica* (2008), Volume 12, Number 4, 497-528, DOI:10.1007/s10707-007-0037-9.

BENKERT, M., GUDMUNDSSON, J., HUBNER, 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.

BERNABEU, E.J., TORNERO, J., TOMIZUKA, M. Collision prediction and avoidance amidst moving objects for trajectory planning applications in: **Robotics and Automation**. (2001) 3801 - 3806 vol.4. ISSN:1050-4729.

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.

CAO H.; MAMOULIS, N.; CHEUNG, D.W. Discovery of collocation episodes in spatiotemporal data. In **ICDM**, pages 823–827. IEEE Computer Society, 2006.

CAO, H., MAMOULIS, N., AND CHEUNG, D. W. Discovery of periodic patterns in spatiotemporal sequences. **IEEE Transactions on Knowledge and Data Engineering**, 19(4):453–467, 2007.

ELNEKAVE, SIGAL; LAST, MARK; MAIMON, ODED. Predicting future locations using clusters' centroids. **Proceedings of the 15th annual ACM international symposium on Advances in geographic information systems**, 2007.

GIANNOTTI, F.; NANNI, M. AND PEDRESCHI, D.. Efficient mining of sequences with temporal annotations. In **Proc. SIAM Conference on Data Mining**, pages 346–357. SIAM, 2006.

GIANNOTTI, F., NANNI, M., PINELLI, F., AND PEDRESCHI, D. Trajectory pattern mining. In **Berkhin, P., Caruana, R., and Wu, X., editors, KDD, ACM**, p. 330–339, 2007.

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.

GUDMUNDSSON, J., VAN KREVELD, M. J., AND SPECKMANN, B. Efficient detection of patterns in 2d trajectories of moving points. **GeoInformática**, 11(2):195–215, 2007.

GUO, DANHUI. Mining Traffic condition from trajectories. **Fifth International Conference on Fuzzy Systems and Knowledge Discovery** (pp. 256-260). Shandong, China: IEEE Computer Society, 2008.

GÜTTING, R. H.; BÖHLEN, M. H.; ERWIG, M.; JENSEN, C. S.; LORENTZOS, N. A.; SCHNEIDER, M.; VAZIRGIANNIS, M. A foundation for representing and quering moving objects. **ACM Trans. Database Syst.**, [S.l.], v.25, n.1, p.1-42, 2000.

HORNSBY, K. Temporal zooming. **Transactions in GIS**, 5, pp. 255–272, 2001.

KIM, DAE-JIN; PARK KWANG-HYUN M.; BIEN, Z. Hierarchical longitudinal controller for rear-end collision avoidance, [s.l.], 2007.

LAUBE, P. AND IMFELD, S. Analyzing relative motion within groups of trackable moving point objects. In Egenhofer, M. J. and Mark, D. M., editors, **GIScience**, volume 2478 of *Lecture Notes in Computer Science*, pages 132–144. Springer, 2002.

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.

LAUBE P., IMFELD S., WEIBEL R. Discovering relative motion patterns in groups of moving point objects, in: **International Journal of Geographic Information Science**, vol. 19, Taylor & Francis Group, pp. 639–668, 2005.

LEE, S.W., LEE, B.H., LEE, K.D. A configuration space approach to collision avoidance of a two-robot system. **Robotica** **17**, 131–141 (1999).

LEE, J.G., HAN, J., LI, X. Trajectory outlier detection: A partition-and-detect framework. In: **ICDE**, pp. 140–149. IEEE (2008).

LIU, Y.H., SHI, C.J. A fuzzy-neural inference network for ship collision avoidance. In: **Proceedings of 2005 International Conference on Machine Learning and Cybernetics**, pp. 4754–4754. IEEE Computer Society (2005)

LOY, A. M., BOGORNY, V., RENSO C., ALVARES L. O. Um algoritmo para identificar padrões comportamentais do tipo *avoidance* em trajetórias de objetos móveis. **GeoInfo** **2010**. Campos do Jordão-SP.

LOY, A. M.; ALVARES,L.O.; RENSO,C.; BOGORNY,V. An Algorithm to Identify Avoidance Behavior in Moving Object Trajectories. In: **Journal of the Brazilian Computer Society**, 2011 (Aceito para publicação).

NEDEVSCHI, SERGIU; BOTA, SILVIU AND TOMIUC, CORNELIU. Stereo-Based Pedestrian Detection for Collision-Avoidance Applications. **Ieee Transactions On Intelligent Transportation Systems**, Vol. 10, No. 3, September 2009.

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.

SHANDY, S., VALASEK, J. Intelligent agent for aircraft collision avoidance. In: **Proceedings of AIAA Guidance, Navigation, and Control Conference**, pp. 1–11. American Institute of Aeronautics and Astronautics (2001).

SOLDERA, JOHN; Detecção de movimentos suspeitos em seqüências de vídeo. **Dissertação de mestrado**, Universidade do Vale do Rio dos Sinos, 2007.

SUH,SUK-HWAN; BISHOP, ALBERT B.. Collision-avoidance trajectory planning using tube concept: Analysis and simulation. – **Journal of Robotic System** **5(6)**, 497-525 (1988).

SUH, SUK-HWAN; KIM, M.S. An algebraic approach to collision-avoidance trajectory planning for dual-robot systems. Formulation and optimization. **Robotica** **10(02)**, 173–182 (1992).