

ESCOLA POLITÉCNICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO  
DOUTORADO EM CIÊNCIA DA COMPUTAÇÃO

CLICÉRES MACK DAL BIANCO

**MODELO PARA A PREDIÇÃO DE COMPORTAMENTO DE MULTIDÃO EM TEMPOS  
FUTUROS**

Porto Alegre

2018

PÓS-GRADUAÇÃO - *STRICTO SENSU*



Pontifícia Universidade Católica  
do Rio Grande do Sul

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO GRANDE DO SUL  
FACULDADE DE INFORMÁTICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO**

**MODELO PARA PREDIÇÃO DE  
COMPORTAMENTOS DE  
MULTIDÃO EM TEMPOS  
FUTUROS**

**CLICÉRES MACK DAL BIANCO**

Tese apresentada como requisito à  
obtenção do grau de Doutor em Ciência  
da Computação na Pontifícia Universidade  
Católica do Rio Grande do Sul.

Orientadora: Prof<sup>a</sup>. Dra. Soraia Raupp Musse

**Porto Alegre  
2018**

## Ficha Catalográfica

D136m Dal Bianco, Clécères Mack

Modelo para predição de comportamentos de multidão em tempos futuros / Clécères Mack Dal Bianco . – 2018.

92.

Tese (Doutorado) – Programa de Pós-Graduação em Ciência da Computação, PUCRS.

Orientadora: Profa. Dra. Raupp Soraia Musse.

1. Multidão. 2. Simulação. 3. Predição. I. Musse, Raupp Soraia.  
II. Título.

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da PUCRS  
com os dados fornecidos pelo(a) autor(a).  
Bibliotecária responsável: Salete Maria Sartori CRB-10/1363

Clicéres Mack Dal Bianco

**Modelo para a Predição de Comportamento de Multidão em Tempos Futuros**

Tese apresentada como requisito parcial para obtenção do grau de Doutor em Ciência da Computação do Programa de Pós-Graduação em Ciência da Computação, Escola Politécnica da Pontifícia Universidade Católica do Rio Grande do Sul.

Aprovada em 10 de Maio de 2018

**BANCA EXAMINADORA:**

Prof. Dr. Creto Augusto Vidal (UFC)

Prof. Dr. Léo Pini Magalhães (UNICAMP)

Profa. Dra. Isabel Harb Manssour (PPGCC/PUCRS)

Profa. Dra. Soraia Raupp Musse(PPGCC/PUCRS - Orientadora)

## AGRADECIMENTOS

A conclusão de um ciclo não é mérito individual mas fruto de pessoas que te impulsionam intelectual e emocionalmente a seguir em frente. Desta forma, deixo minha gratidão a todos que contribuíram com este trabalho especialmente à Deus por ter me dado força e saúde.

Inicializo agradecendo a minha orientadora professora Soraia R. Musse, que tenho admiração desde da primeira aula que assisti. Obrigada por estar sempre presente, pelas valiosas orientações e pelos incasáveis ensinamentos que foram imprescindíveis durante o doutorado.

Agradeço aos professores da banca Léo Pini Magalhães, Creto Vidal e Isabel Harb Manssour pela leitura, contribuições e correções permitindo enriquecer este trabalho.

Agradeço a Adriana Braun pela contribuição fundamental no desenvolvimento do modelo desta tese, obrigada por toda a paciência e conhecimentos transmitidos. Também agradeço aos demais colegas do VHLab, principalmente, Leandro Dihl, Adriana Braun, Rodolfo Favaretto, Vinícius Cassol, Amyr Borges e Paulo Knob por todas as trocas de experiências, auxílio e amizade, espero reencontrá-los nos caminhos da vida.

Agradeço meus colegas e amigos da URI, principalmente aos que convívio diariamente André Stefanello, Catiane Priscila Barbosa, Cristian Cleder Machado, Maurício Sulzbach e Marcos A. Ritterbuch pelo apoio, colaboração com as disciplinas e com as demais atividades que assumiram para que conseguisse realizar o doutorado e principalmente pela amizade.

Agradeço a Micheli Klen por toda a dedicação, profissionalismo e lembretes. Obrigada por ser tão eficiente em atender as demandas da coordenação de área. Durante as fases difíceis anjos surgem nas nossas vidas!

Agradeço a Marinês Aires por ter me apresentado a família de PoA, o período de doutorado a partir desta convivência se tornou mais leve. Obrigada Franci, Renata, Marinês, Carol, Larissa, Ana Letícia, Jucimar e Rubriane foi bom dividir com vocês as angústias e as conquistas.

Agradeço ao meu esposo, Sandro R. Giacomelli, que foi um grande incentivador e apoiador durante essa fase. Obrigada por entender as ausências e por todas as palavras de estímulo, principalmente, aos domingos, antes das viagens a PoA que pensava em desistir

you reminded me that to achieve dreams are necessary sacrifices. This conquest is also yours!

I thank my parents, Mauri and Dilva, for the constant demonstration of wisdom and humility and support over these years. I thank my brothers Deoclécio, Leticia and Joao for the support and for making my life happy.

# MODELO PARA PREDIÇÃO DE COMPORTAMENTOS DE MULTIDÃO EM TEMPOS FUTUROS

## RESUMO

O comportamento de multidões humanas tem sido objeto de estudo de diversas áreas do conhecimento, tais como Ciências Humanas, Engenharias e Ciência da Computação. No âmbito da Ciência da Computação as simulações de multidões geram informações que servem de base para desenvolvimento de pesquisas com aplicações voltadas para a segurança e o entretenimento. O objetivo deste trabalho é prover um modelo computacional que estime o comportamento da multidão em determinado tempo futuro. Métodos como *Pedestrian Dead Reckoning (PDR)* possibilitam uma predição aproximada das posições das pessoas em tempos futuros, usando hipóteses Físicas. No entanto, o desafio está em gerar posições precisas considerando comportamentos realísticos de multidões em ambientes complexos, onde a estimativa somente usando Física dos movimentos dos pedestres, pode não ser robusta suficientemente. Neste trabalho propõe-se um modelo denominado *Time Machine (TM)* que estende o conceito de *PDR* com dados das interações entre pessoas e complexidade do ambiente. Este modelo foi integrado ao BioCrowds, um simulador de multidões que discretiza as áreas disponíveis do ambiente e as representa através de marcadores (pontos no espaço) que permitem a movimentação, livre de colisão, de humanos virtuais. A fim de validar a metodologia proposta, diversas simulações foram executadas incluindo estudos de casos com situações reais. Para esses estudos de caso, as análises de erro incluíram informações de densidade e de variação de posições dos personagens. Um exemplo é a predição de 8,33 segundos no tempo futuro de uma população simulada de 320 agentes em uma área livre de 338m<sup>2</sup>, sendo que a diferença média das posições, com o método *Time Machine*, foi de 0,25. Além disso, para casos com dados reais, o método *TM* estimou a multidão com o erro máximo de 0,24.

**Palavras-Chave:** Multidão, Simulação, Predição.

# MODEL FOR PREDICTING CROWD BEHAVIORS IN FUTURE TIMES

## ABSTRACT

The behavior of human crowds has been studied in several areas of knowledge, such as Human Sciences, Engineering and Computer Science. In the field of Computer Science, crowd simulations generate information that serves as the basis for the development of research with applications focused on security and entertainment. The objective of this work is to provide a computational model that estimates the behavior of the crowd at a certain future time. Methods such as *Pedestrian Dead Reckoning (PDR)* allow an approximate prediction of people's positions in future times, using Physical hypotheses. However, the challenge is to generate accurate positions by considering realistic behavior of crowds in complex environments, where the estimation using only the physics of pedestrian movements may not be robust enough. This paper proposes a model called *Time Machine (TM)* that extends the concept of *PDR* with data resulting from interactions among people and complexity of the environment. This model has been integrated with BioCrowds, a crowd simulator that discretizes the available areas of the environment and represents them through markers (points in space) that allow the free movement of virtual humans. In order to validate the proposed methodology, several simulations were performed including case studies with real situations. For these case studies, analyzed error includes information on density and variation of pedestrian positions. An example is the prediction of 8.33 seconds in the future time of a simulated population of 320 agents in a free area of 338m<sup>2</sup>, presenting the error of 0.25 in average. In addition, for cases with real data, the *TM* method estimated the crowd with the maximum error of 0.24.

**Keywords:** Crowd simulation, Prediction, Pedestrian Dead Reckoning.

## LISTA DE FIGURAS

Figura 1.1 – Dinâmica da solução proposta . . . . .	18
Figura 2.1 – Ilustração das classificações de multidão: (a) Casual, (b) Convencional, (c) Manifestante, e (d) Violenta . . . . .	21
Figura 2.2 – Representação de 5 agentes e seus respectivos espaços pessoais (extraída de Lima Bicho [8]) . . . . .	27
Figura 3.1 – Resultados obtidos por Berseth e colegas [6] . . . . .	35
Figura 3.2 – Esquema dos diferentes domínios do problema que foram propostos em Kapadia et al. [38]. . . . .	36
Figura 4.1 – Exemplo de pares de simulação empregados no cálculo do atrapalhamento . . . . .	43
Figura 4.2 – Histogramas de redução de velocidade nos pares de d simulações do BioCrowds e redução de velocidades geradas aleatoriamente de acordo com a distribuição Weibull (em m/s) . . . . .	44
Figura 4.3 – Fluxo de dados durante a simulação. (a) Avanço de tempo sem evento (TM). (b) Dinâmica do avanço de tempo com eventos (TM-E) considerando eventos $\tau_2 = 1$ e $\tau_2 = 2$ . . . . .	48
Figura 5.1 – Diferentes cenários usados para a avaliação. (a) sem obstáculos. (b) 2 obstáculos. (c) 4 obstáculos e (d) 6 obstáculos . . . . .	52
Figura 5.2 – Resultados para o cenário sem obstáculos. (a) Diferenças em relação às posições. (b) Diferenças em relação às densidades para todas as população nos três instante de análise. Imagens da simulação contínua (segunda linha) e da TM com líder (terceira linha) para uma população com 80 agentes no cenário sem obstáculo. (c) e (f) <i>frame</i> de pausa. (d) e (g) <i>frame</i> da volta ( $t_1$ ). (e) e (h) segundo instante de análise ( $t_2$ ) . . . . .	54
Figura 5.3 – Resultados do cenário com dois obstáculos.(a) Diferenças de Posições. (b) Diferenças de Densidades. As imagens do centro referem-se à simulação contínua e as imagens da parte inferior pertencem a TM com líder. (a) e (d) <i>frame</i> de pause - $t$ . (b) e (e) $t_1$ - <i>frame</i> da volta. (c) e (f) segundo instante de análise - $t_2$ . . . . .	55

Figura 5.4 – (a) e (b) Resultado da métrica de posição e densidade, respectivamente, para todas as população nos três instante de análise no cenário com quatro obstáculos. Capturas de tela do cenário com seis obstáculos nas simulações com 80 agentes, as imagens da primeira linha referem-se a simulação contínua e as imagens (f) à (h) referem-se a simulação TM com líder. (a) e (d) <i>frame</i> de pause - $t$ . (b) e (e) <i>frame</i> da volta - $t_1$ . (c) e (f) segundo instante de análise - $t_2$ . . . . .	56
Figura 5.5 – Resultados para o cenário com seis obstáculos.(a) Diferenças de Posições. (b) Diferenças de Densidades. As imagens do centro referem-se a simulação contínua e as imagens da parte inferior pertencem a TM com líder. (c) e (f) <i>frame</i> de pause. (d) e (g) $t_1$ <i>frame</i> da volta. (e) e (h) segundo instante de análise $t_2$ . . . . .	57
Figura 5.6 – Distância média quando comparadas as simulações com <i>Time Machine</i> com as simulações contínuas . . . . .	59
Figura 5.7 – Ilustração do cenário com diferentes distribuições de marcadores. (a) Distância padrão entre os marcadores igual a 0,175. (b) Distância reduzida entre marcadores igual a 0,06 . . . . .	60
Figura 5.8 – Analise das diferenças de posições, nos quatro cenários, com duas distribuição de marcadores e em três instante de tempo das simulações ( $t_1$ , $t_2$ e $t_3$ ) . . . . .	61
Figura 5.9 – Análise das diferenças de densidades no instante da volta ( $t_1$ ), nos quatro cenários, com distribuição de marcadores reduzida . . . . .	62
Figura 5.10 – (a) <i>Frame</i> de parada da simulação contínua e da <i>Time Machine</i> . (Topo) Simulação sem <i>Time Machine</i> : (b) primeiro instante de análise ( $t_1$ ), (c) segundo instante de análise ( $t_2$ ). (Abaixo) Simulação com <i>Time Machine</i> : (d) instante após o avanço ( $t_1$ ), (e) 8 segundos após o avanço ( $t_2$ ). . .	63
Figura 5.11 – (a) Instante de pause da simulação contínua e da <i>time machine</i> ( $t$ ). (Topo) Simulação contínua: (b) primeiro instante de análise ( $t_1$ ), (c) segundo instante de análise ( $t_2$ ). (Abaixo) Simulação com <i>time machine</i> : (d) instante da finalização do avanço no tempo ( $t_1$ ), (e) 4 segundos após o avanço ( $t_2$ ) . . . . .	63
Figura 5.12 – a) <i>Frame</i> de parada da simulação contínua e da <i>Time Machine</i> . (Topo) Simulação sem <i>Time Machine</i> : (b) primeiro instante de análise ( $t_1$ ), (c) segundo instante de análise ( $t_2$ ). (Abaixo) Simulação com <i>Time Machine</i> : (d) instante após o avanço ( $t_1$ ), (e) 4,1 segundos após o avanço ( $t_2$ ) . . . . .	64

Figura 5.13 – Cada linha mostra a configuração para cada população. Linhas horizontais vermelhas definem o início e o fim de um evento, setas verticais amarelas indicam os <i>frames</i> de análise e as barras cinzas-escuras o tempo em que o método TM-E acontece . . . . .	65
Figura 5.14 – Diferenças de densidades observadas nas três comparações relacionadas de um evento $\tau_1 = 1$ . . . . .	67
Figura 5.15 – Imagens das simulações (linhas a e c) e do método TM-E (linhas b e d) com 80 e 320 agentes, respectivamente, com evento $\tau_1 = 1$ e $\sigma_1 = 1$ . .	67
Figura 5.16 – Diferenças de densidades observadas nas três comparações relacionadas com evento $\tau_1 = 1$ e $\sigma_1 = 2$ . . . . .	68
Figura 5.17 – Imagens das simulações (linhas a e c) e do método TM-E (linhas b e d) com 80 e 320 agentes, respectivamente, com evento $\tau_1 = 1$ e $\sigma_1 = 2$ . . .	68
Figura 5.18 – As linhas mostram a configuração de cada população. Linhas horizontais vermelhas indicam o início e o fim de um evento, setas verticais amarelas apontam os <i>frames</i> de análise e as barras cinzas, o tempo em que o método TM-E acontece . . . . .	69
Figura 5.19 – Diferenças de densidades observadas nas três comparações relacionadas, com evento $\tau_1 = 2$ . . . . .	70
Figura 5.20 – Imagens das simulações (linhas a e c) e do método TM-E (linhas b e d) com 80 e 320 agentes, respectivamente, com evento $\tau_1 = 2$ . . . . .	71
Figura 5.21 – Diferenças de densidades observadas nas três comparações relacionadas para eventos $\tau_k = 3$ . . . . .	71
Figura 5.22 – Os cinco cenários reais utilizados para demonstrar o método. (a) Primeiro Cenário. (b) Segundo Cenário. (c) Terceiro Cenário. (d) Quarto Cenário. (e) Quinto Cenário . . . . .	73
Figura 5.23 – Um exemplo de distribuição de pessoas no <i>frame</i> 60 (de acordo com a imagem à esquerda) e uma demonstração após 50 <i>frames</i> com um adicional de 12 pessoas (conforme o destaque em vermelho da figura à direita). A simulação TM-E considera esse adicional como evento . . . . .	73
Figura 5.24 – Resultados do primeiro caso de estudo. (a) Diferenças de posições. (b) Diferenças de densidades. (c), (d) e (e) Imagem do <i>frame</i> 110 do vídeo e da simulação contínua e da simulação com TM-E, respectivamente . . . . .	75
Figura 5.25 – Capturas de tela do segundo cenário. (a) <i>Frame t</i> do vídeo. (b) <i>Frame t<sub>1</sub></i> do vídeo (c) <i>Frame t</i> do experimento TM-E. (d) <i>Frame t<sub>1</sub></i> do experimento TM-E. . . . .	76
Figura 5.26 – Capturas de tela do terceiro cenário. (a) <i>Frame t</i> do vídeo. (b) <i>Frame t<sub>1</sub></i> do vídeo (c) <i>Frame t</i> do Experimento TM-E. (d) <i>Frame t<sub>1</sub></i> do Experimento TM-E. . . . .	77

Figura 5.27 – Capturas de tela do quarto cenário. (a) <i>Frame t</i> do vídeo. (b) <i>Frame t<sub>1</sub></i> do vídeo. (c) <i>Frame t</i> do experimento TM-E. (d) <i>Frame t<sub>1</sub></i> do experimento TM-E . . . . .	78
Figura 5.28 – Informações do quinto cenário. (a) <i>Frame t</i> do vídeo. (b) <i>Frame t<sub>1</sub></i> do vídeo (c) <i>Frame t</i> do Experimento TM-E. (d) <i>Frame t<sub>1</sub></i> do Experimento TM-E . . . . .	79
Figura 5.29 – Diferenças agrupadas por experimento com as simulações inicializadas no instante <i>t</i> . (a) Resultados das diferenças entre as posições do vídeo e as posições da simulação contínua. (b) Resultados das diferenças de posições entre TM-E e o vídeo . . . . .	81
Figura 5.30 – Correlação entre as diferenças de densidades e as diferenças de posições.(a) Correlação entre as diferenças de posições e densidades obtidas no experimento Contínuo. (b) Correlação entre as diferenças de posições e densidades do método TM-E. (c) Correlação entre as diferenças de posições e densidades obtidas em ambos os experimentos . . . . .	82

## LISTA DE TABELAS

Tabela 4.1 – Descrição da notação. Símbolos com seta ( $\vec{\phantom{x}}$ ) representam vetores, barras ( $  $ ) indicam módulo e demais notações representam variáveis escalares .....	38
Tabela 4.2 – Dados da simulação com um agente .....	40
Tabela 5.1 – Relação de <i>frames</i> nos quais executaram-se as análises. O <i>frame</i> da volta está especificado na terceira coluna $t_1$ , e os outros instantes das análises são apresentados nas colunas identificadas como $t_2$ e $t_3$ .....	54
Tabela 5.2 – Dados dos experimentos. <i>Frame</i> de pause $t$ , o <i>frame</i> da volta $t_1$ , tempo de ocorrência dos eventos e o sentido $\tau_k = 2$ .....	74

## LISTA DE SIGLAS

DR – *Dead Reckoning*

PDR – *Pedestrian Dead Reckoning*

VHLAB – Laboratório de Visualização de Humanos Virtuais

TM – *Time Machine*

TME – *Time Machine* com Eventos

ORCA – *Optimal Reciprocal Collision Avoidance*

RVO – Recíproca Velocidade em Obstáculo

LOD – *Level Of Detail*

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>16</b>
1.1	Contextualização da Proposta	17
1.2	Objetivos	18
1.2.1	Objetivo Geral	18
1.2.2	Objetivos Específicos	19
1.3	Organização da tese	19
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>20</b>
2.1	Multidão	20
2.1.1	Movimentação	21
2.1.2	Comportamento de Multidão	22
2.2	Algoritmos de Navegação e Direção	23
2.2.1	Planejamento de Caminho	24
2.2.2	Direção	24
2.3	BioCrowds	26
<b>3</b>	<b>TRABALHOS RELACIONADOS</b>	<b>29</b>
3.1	Simulação de Multidões	29
3.1.1	Modelos Macroscópicos	30
3.1.2	Modelos Microscópicos	31
3.1.3	Custo Computacional	31
3.2	Dead-Reckoning	32
3.3	Complexidade de ambientes	34
3.4	Contextualização da proposta no Estado da Arte	36
<b>4</b>	<b>MODELO PROPOSTO PARA PREDIÇÃO DE COMPORTAMENTO FUTURO DE MULTIDÃO</b>	<b>38</b>
4.1	Etapas do Modelo <i>Time Machine</i>	39
4.1.1	Estimar a posição prévia dos agentes	39
4.1.2	Analisar a Complexidade do Ambiente	41
4.1.3	Calcular a Interação entre as Pessoas	42
4.1.4	Reposicionamento dos agentes	44
4.2	Inclusão e Tratamento de Eventos	45

4.3	Integração com o BioCrowds . . . . .	48
<b>5</b>	<b>RESULTADOS</b> . . . . .	<b>50</b>
5.1	Método: <i>Time Machine</i> com Líder . . . . .	50
5.1.1	Experimentos com Líder . . . . .	52
5.1.2	Validação <i>Time Machine</i> com Líder . . . . .	52
5.1.3	Análise geral considerando os quatro cenários e a <i>TM</i> com líder . . . . .	57
5.2	Experimentos com a <i>Time Machine</i> com Estimativas . . . . .	58
5.2.1	Validações e Comparações . . . . .	58
5.3	Experimentos com Cenários Dinâmicos . . . . .	64
5.3.1	Caso A: Investigação do impacto do evento $k$ tipo $\tau_k = 1$ . . . . .	65
5.3.2	Caso B: Investigação do impacto do evento $k$ tipo $\tau_k = 2$ (população) durante o avanço de tempo . . . . .	69
5.3.3	Caso C: Investigação do impacto do evento $k$ tipo $\tau_k = 3$ (obstáculos e população) durante o avanço de tempo . . . . .	70
5.4	Experimentos com Cenários Reais . . . . .	72
5.4.1	Primeiro Cenário de Estudo: Fluxo Unidirecional (Figura 5.22(a)) . . . . .	75
5.4.2	Segundo Cenário de Estudo: Fluxo Bidirecional e Sentidos Opostos (Fig. 5.22(b)) . . . . .	76
5.4.3	Terceiro Cenário de Estudo: Fluxo Unidirecional com Obstáculo (Figura 5.22(c)) . . . . .	77
5.4.4	Quarto Cenário de Estudo: Fluxo Bidirecional (Figura 5.22(d)) . . . . .	78
5.4.5	Quinto Cenário de Estudo: Fluxo Bidirecional com Obstáculos (Figura 5.22(e)) . . . . .	79
5.4.6	Análises dos Experimentos . . . . .	80
<b>6</b>	<b>CONSIDERAÇÕES FINAIS</b> . . . . .	<b>83</b>
6.1	Publicações . . . . .	85
	<b>REFERÊNCIAS</b> . . . . .	<b>86</b>

# 1. INTRODUÇÃO

A elevada densidade populacional tornou as multidões parte do cotidiano da maioria das cidades, que por sua vez precisam adaptar e planejar espaços físicos para comportá-las. Além do espaço físico, outro fator que merece atenção é a imprevisibilidade do comportamento coletivo que pode despertar ações, em massa, negativas ou positivas. A área de Ciências Humanas, desde 1985 investe esforços para entender a complexidade inerente das relações coletivas [46]. As áreas das Engenharias e Ciência da Computação corroboram com estudos relacionados a multidão [82]. Especificamente as pesquisas voltadas para a Engenharia de Segurança analisam situações que podem causar conflitos em aglomerados e elaboram diretrizes para evitá-las [70].

Em particular, a área da Computação contribui com investigações e desenvolvimento de técnicas que possibilitem simular computacionalmente os comportamentos de multidão [55], bem como representar pessoas através de humanos virtuais [35]. Essas técnicas podem ter aplicações em segurança e em entretenimento. Em segurança são consideradas situações de aglomerações em ambientes como estádios de futebol, escolas, boates, estações de trem, aeroportos, entre outros. O desafio tem sido incluir comportamentos realísticos, permitindo simular diversas situações reais, sem colocar em risco a vida das pessoas, e determinar o tempo de abandono, número máximo de pessoas que o ambiente comporta, número ideal de saídas e etc [63, 76]. Na indústria de entretenimento, o principal objetivo da simulação de multidões é preencher cenas de jogos e filmes com um grande número de humanos virtuais, que possuam comportamentos realísticos e dinâmicos [53, 39].

As simulações de multidões são modeladas computacionalmente a partir de métodos classificados como macroscópicos ou microscópicos. Os métodos macroscópicos são usados em situações onde a individualidade dos elementos não é relevante, mas a "inteligência" do modelo encontra-se no comportamento coletivo [53]. Enquanto que os métodos microscópicos focam principalmente nas características emergentes de ações individuais [82, 84]. Independente do método usado para a simulação, as técnicas evoluíram e possibilitam atualmente projetar, com auxílio de computador, diversos contextos e conduzir experimentos abrangendo comportamentos heterogêneos [14], contágio de emoções [10], multidões de alta densidade [42] situações que envolvem tumultos [1], entre outras. Outra abordagem é estimar ou prever o estado futuro de uma multidão. A predição em simulação de multidão pode ser observada como uma importante ferramenta de diagnóstico futuro, permitindo anteceder situações de risco, e com isso medidas de segurança podem

ser tomadas para evitá-las. As pesquisas voltadas à predição futura de multidão ainda são restritas e, dada a sua importância, há um longo caminho a ser explorado [27, 16]. Contudo, para a estimativa de movimentos de personagens virtuais existem métodos como *Dead Reckoning* (DR), que neste caso, a partir de uma posição conhecida estima, por meio da cinemática, a próxima posição. Da mesma forma, o método *Pedestrian Dead Reckoning* (PDR) usa como base DR e realiza estimativa de velocidades e direções de caminhada. Essa técnica tem como enfoque o posicionamento de pedestres na vida real [43, 44, 67].

Entretanto, nenhum dos métodos supracitados visa contribuir para a simulação de multidões. Sendo assim, este é o objetivo principal desta tese: elaborar um modelo que, a partir das estimativas originárias das técnicas de PDR, realize a predição de comportamentos futuros de multidões, tendo como escopo multidões de até 320 agentes e cenários contendo obstáculos com geometria regular.

## 1.1 Contextualização da Proposta

Este trabalho integra as pesquisas de simulações computacionais do VhLab<sup>1</sup>, com viés para a determinação de comportamento futuro de multidões. O ponto de partida, para o desenvolvimento do modelo proposto nesta pesquisa foi determinar as posições dos indivíduos em dado instante e estudar os fatores que impactam na redução de velocidade e desvio de orientação. Ainda, realizaram-se experimentos para verificar como a complexidade do ambiente interfere nos deslocamentos. O desafio foi avançar no tempo a simulação de multidão, preservando as características dos indivíduos (velocidade e direção). A Figura 1.1 ilustra a dinâmica da solução proposta nesta tese. A imagem da Figura 1.1(a) apresenta o instante de tempo ( $t$ ) em que a simulação foi pausada com dois grupos de agentes em direção contrária. Neste momento, o método denominado *Time Machine* extrai as informações da população e do ambiente (Figura 1.1(b)). A *Time Machine* processa essas informações e realiza as estimativas do comportamento da multidão em dado instante de tempo no futuro (Figura 1.1(c)). O resultado após o avanço de tempo é apresentado na Figura 1.1(d). Posteriormente a simulação pode ser retomada ou finalizada.

Um método capaz de prever o estado da simulação em tempo futuro possui potenciais aplicações. A seguir, citam-se dois exemplos:

- Anteceder situações de riscos e possibilitar que medidas de segurança sejam adotadas. Imagine um segurança visualizando uma área interna de um *shopping* com vários acessos, observando (ou recebendo) análises de taxas de movimento em uma direção específica, assim o segurança pode prever quando a área ficará lotada e antecipar ações, por exemplo, direcionando pessoas para outro local, evitando possível

---

<sup>1</sup>Laboratório de Visualização de Humanos Virtuais -VhLab

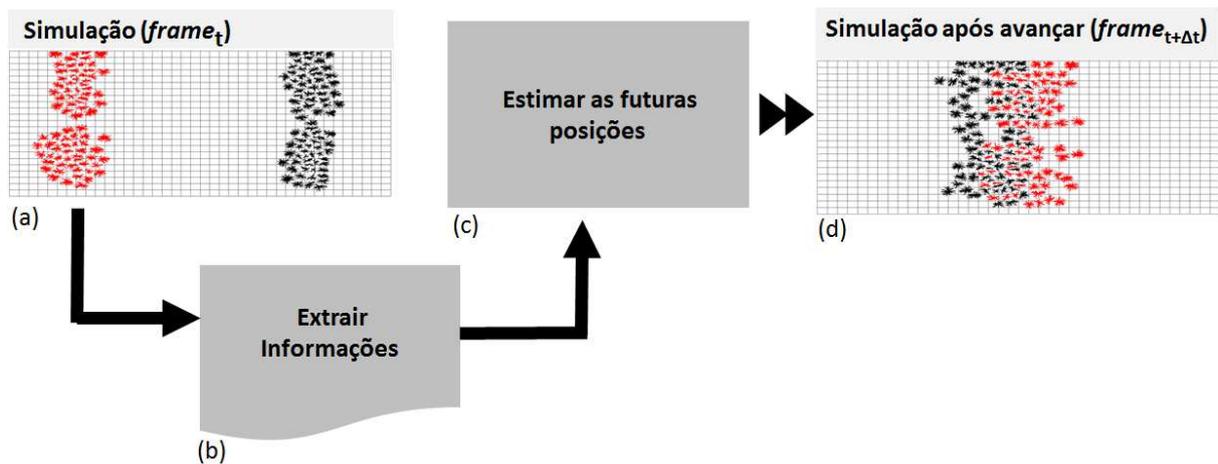


Figura 1.1 – Dinâmica da solução proposta

tumulto. Se não resolvido, este é um exemplo de situação que pode resultar em desordem, pois situações que individualmente não têm impacto podem ser geradores de eminentes confusões e violências quando ocorrem em grandes aglomerados [51], portanto esforços para preveni-las são válidos e relevantes.

- Minimizar o custo de processamento computacional em jogos, pois é rotineiro o interesse somente por determinada cena do jogo. Neste caso, o que não está no campo de visão do observador pode ser estimado, economizando processamento e mantendo o comportamento realístico.

Assim, este trabalho visar apresentar métodos que, a partir das características extraídas de simulações existentes, permitem a predição da multidão em um instante desejado. A próxima seção detalha os objetivos deste trabalho.

## 1.2 Objetivos

### 1.2.1 Objetivo Geral

Este trabalho tem como objetivo principal a predição de comportamentos futuros de multidão, a partir do modelo *Time Machine*. Baseado em fatores como número de indivíduos, velocidades, direções, área disponível e dados dos obstáculos (dimensão e posição), visa parametrizar o impacto desses fatores na previsão de parâmetros futuros da multidão. Esses parâmetros foram incorporados na técnica *PDR*, possibilitando assim estimar a posição futura da multidão.

### 1.2.2 Objetivos Específicos

- Desenvolvimento de um método para calcular a estimativa prévia das posições por meio de *Pedestrian Dead Reckoning* (PDR);
- Identificação do impacto das interações entre agentes (no mesmo sentido e no sentido contrário) na redução de velocidade e integração dessa redução de velocidade no método *PDR* para, assim, melhorar a precisão da estimativa futura dos indivíduos;
- Determinação de um fator que incorpore a complexidade do ambiente, considerando o quanto os obstáculos impactam na direção e velocidade, a fim de ajustar a estimativa oriunda do método *PDR*;
- Realização de experimentos utilizando cenários com diferentes configurações de população e de ambiente, a fim de validar o modelo *Time Machine*; e
- Testar a eficiência da metodologia desenvolvida em vídeos reais.

### 1.3 Organização da tese

A tese está organizada da seguinte maneira: o Capítulo 2 é composto pela fundamentação teórica referente ao comportamento de multidões os principais métodos para a movimentação de pessoas e também realiza a apresentação do simulador de multidões BioCrowds, utilizado como ferramenta base no desenvolvimento neste trabalho. O Capítulo 3 contempla os principais trabalhos relacionados à área de pesquisa a ser explorada nesta tese. O Capítulo 4 apresenta o modelo desenvolvido para a predição de multidão. Os experimentos realizados e resultados obtidos são detalhados no Capítulo 5. Finalmente, o Capítulo 6 discute as considerações finais e indica trabalhos futuros a serem realizados.

## 2. FUNDAMENTAÇÃO TEÓRICA

Este capítulo tem como objetivo apresentar alguns fundamentos teóricos para o embasamento dos próximos capítulos. Inicialmente, apresentam-se conceitos e aspectos relacionados à dinâmica de multidões e algumas características comportamentais das multidões. Em seguida, são apresentadas algumas técnicas utilizadas na simulação de multidão. Ainda, é apresentado o modelo BioCrowds, desenvolvido para simular multidões, o qual foi estendido para contemplar o objetivo deste tese.

### 2.1 Multidão

Multidões são consideradas sistemas complexos [23] formados por aglomerados de indivíduos (grupos de pessoas), rebanhos de animais ou enxames de insetos, entre outros. Esses aglomerados devem estar presentes fisicamente no mesmo local [53]. Devido à sua dinâmica, a multidão é considerada um fenômeno fascinante, sendo constantemente estudada por psicólogos, sociólogos, biólogos, físicos, engenheiros e cientistas da computação [82]. Ainda, de acordo com os autores Challenger e Clegg [16], não há uma definição de multidão que seja de senso comum a todos os pesquisadores, dada a grande variabilidade de coleções possíveis. No entanto, segundo alguns autores [53, 77], no que tange à multidão de humanos, certos pontos são comuns: *i)* Tamanho: deve haver um encontro considerável de pessoas. *ii)* Densidade: compartilhar o mesmo local com distribuição de densidade razoável. *iii)* Tempo: as pessoas se reúnem para uma finalidade específica por um período de tempo mensurável. *iv)* Coletividade: membros da multidão devem compartilhar objetivos e interesses, além de agirem de uma forma coerente.

Os pesquisadores Thalmann e Musse [76] fazem uma importante distinção entre uma multidão física e uma multidão psicológica. A multidão física está relacionada a um grupo de pessoas que simplesmente compartilham um local. No caso de uma multidão psicológica, trata-se de um grupo de pessoas que também compartilham uma identidade social.

As multidões podem ser classificadas para facilitar o planejamento e o gerenciamento das questões relacionadas com a segurança. Nos trabalhos de Berlonhi [4], Challenger e Clegg [16] essa classificação foi feita de acordo com o tipo de público e ficou estabelecida da seguinte forma:

a) **Multidão Casual:** Esse tipo de multidão é momentânea. Os integrantes têm atenção temporária e breve para o objeto de interesse e a interação entre esses membros não é intensa. Por exemplo, pessoas passeando em um shopping, atravessando a rua ou assistindo a um artista em uma vitrine de loja (Figura 2.1(a)).

b) **Multidão Convencional:** São pessoas que se reúnem para um evento agendado, compartilham de um objetivo comum com interações prováveis. Por exemplo, espectadores de um evento esportivo ou de um show (Figura 2.1(b)).

c) **Multidão Manifestante:** Neste caso, existe a figura de um líder e o agrupamento organizado ocorre por alguma razão ou evento específico. Por exemplo, protesto ou reivindicação de algo (Figura 2.1(c)).

d) **Multidão Violenta:** São aglomerados de pessoas que provocam tumultos, desrespeitam a lei. Por exemplo, grupo de linchadores que tenta agredir alguém ou destruir algo (Figura 2.1(d)).



Figura 2.1 – Ilustração das classificações de multidão: (a) Casual, (b) Convencional, (c) Manifestante, e (d) Violenta

### 2.1.1 Movimentação

De acordo com Fruin [23] apud [53], o espaço físico exerce influência na movimentação de grupos de pessoas, ou seja, a forma como as pessoas se deslocam no ambiente e se posicionam em relação às demais leva em consideração como avaliam e detectam o espaço. Considerando o espaço ao redor das pessoas durante interações e comunicações, o antropólogo Edward Twitchell Hall, em 1966, criou o termo proxêmica (proxemics), para descrever como as pessoas percebem e utilizam o espaço em distintos ambientes [28]. O antropólogo propôs uma classificação considerando a relação entre as percepções humanas e possíveis distâncias interpessoais:

a) **Distância íntima:** quando a distância varia entre 15 e 45 centímetros. Os detalhes faciais (íris e poros) são nitidamente percebidos. A distância íntima é percebida em relações de estreito convívio onde o contato físico não é evitado.

b) **Distância Pessoal:** a distância entre as pessoas varia entre 45 centímetros e 1,2 metro. Nesta distância, características faciais (detalhes da pele, dentes e cabelos) são

claramente visíveis. Essa distância é percebida quando há uma relação de amizade e assuntos de interesses pessoais são abordados.

c) Distância Social: nesta classificação a distância entre as pessoas varia entre 1,2 e 3,6 metros. Nesta distância, é possível identificar alguns detalhes faciais. É uma distância usual para as pessoas que estão participando de um evento social ou casual que envolva conversas formais ou negociações. E

d) Distância Pública: neste caso a distância é maior ou igual a 3,6 metros. Detalhes faciais não são visíveis (por exemplo: manchas na pele e cor dos olhos são imperceptíveis). Essa situação é percebida em interações onde não há envolvimento pessoal. De acordo com Challenger e Clegg [16], cabe ressaltar que essas distâncias foram estipuladas baseadas na cultura norte-americana e podem sofrer alterações conforme padrões comportamentais de cada cultura.

### 2.1.2 Comportamento de Multidão

A forma de agir das multidões deve ser considerada nos estudos de simulação de multidão, a fim de obter resultados condizentes com as situações reais. Pan e seus colegas afirmam que uma multidão não pode ser tratada exclusivamente como um conjunto de indivíduos [58]. Na obra sobre psicologia das massas, o psicólogo social e físico Le Bon [46] constata que os comportamentos coletivos apresentados pelos indivíduos, na maioria das vezes, diferem da sua maneira de agir quando estão sozinhos. Corroborando com Le Bon, Turner [78] afirma que um indivíduo é capaz de mudar o seu comportamento em função do contexto e do grupo social o qual está inserido. Ao se identificar como membro de um determinado grupo, o indivíduo também passa a ser classificado pelas características desse grupo, e em alguns casos o senso de responsabilidade individual passa a ser esquecido [46]. A partir da análise das pesquisas de Helbing [31], Fruin [23] e Still [73] o trabalho de Bicho [8] classifica os comportamentos de multidões em duas categorias: aqueles considerados como inerentes e aqueles definidos como emergentes. Comportamentos inerentes buscam retratar comportamentos adotados por um ser humano resultantes do seu estado mental (ponderando crenças, desejos e emoções) que o fazem deslocar-se da melhor maneira possível em um ambiente social. Dentre esses comportamentos, destacam-se aqueles em que o indivíduo desloca-se procurando: a) evitar colisão: caracterizado pelo comportamento das pessoas se deslocarem evitando colidir com obstáculo ou com outras pessoas; b) minimizar o esforço despendido: refere-se ao fato de as pessoas procurarem escolher trajetórias que demandem menos esforço ou minimizam a variação de orientação em relação ao destino pretendido.

Os comportamentos emergentes foram conceituados por Bicho [8] como aqueles que contribuem para a auto-organização coletiva. O pesquisador apontou duas características que auxiliam na auto-organização das multidões:

a) Formação de vias de pedestres (*lanes*), em uma situação de multidão, onde as pessoas organizam-se em uma espécie de fila para facilitar o deslocamento. De modo geral, uma pessoa seguirá aquela imediatamente à sua frente, quando ambas se locomovem na mesma direção, mantendo velocidade menor ou igual à dela.

b) Efeito de redução da velocidade ocasionado pela alta densidade de indivíduos no mesmo espaço. Assim, quanto maior a densidade de pedestres, menor é a velocidade deles. Além disso, outra causa para este efeito também pode ser o fato de dois grupos cruzarem-se durante a movimentação.

Após definir-se comportamento de multidão e as particularidades relacionadas à ação coletiva, a próxima seção apresenta alguns algoritmos de navegação e direção que devem estar presentes nas ferramentas de simulação para que as soluções possam refletir comportamentos realistas.

## 2.2 Algoritmos de Navegação e Direção

O principal objetivo da área de simulação de multidão consiste em determinar o movimento de diversos agentes e suas particularidades, tais como velocidade e espaço pessoal, mas sem deixar de representar o comportamento coletivo. Aliado a esse objetivo está o interesse de representar o mundo real na sua totalidade, incluindo obstáculos estáticos (estruturais, tais como portas e paredes, ou de população, tais como grupos de pessoas paradas) e obstáculos dinâmicos (tais como automóveis e pessoas em movimento). Para suprir essas necessidades, surgem algumas técnicas. A pesquisa de Kapadia et al [39], por exemplo, apresenta de forma detalhada várias dessas técnicas e algoritmos que possibilitam a representação do mundo ou da área de interesse e a movimentação (navegação) em cenários virtuais. Além disso, detalha métodos para visualização 3D e renderização das simulações de multidão. As técnicas relacionadas à movimentação e à prevenção de colisão, que utilizam agentes, são as correlacionadas com esta tese e serão brevemente apresentadas. Kapadia e colegas [39] diferenciam as técnicas de planejamento de caminho e direção conforme as definições a seguir:

a) Planejamento de Caminho: é o processo de buscar um caminho global livre de colisão a partir da posição inicial de um agente até o seu destino. Os métodos de planejamento de caminho em ambientes complexos e grandes exigem um agente equipado com um modelo mental que forneça algo semanticamente significativo como a representação geométrica do mundo à sua volta.

b) Direção: são os métodos que fazem interface com as técnicas planejamento de caminho, possibilitando movimentar um agente ao longo do caminho. Esses métodos realizam sucessivas buscas locais para identificar e evitar obstáculos estáticos e dinâmicos. As próximas seções discorrem sobre esses tópicos.

### 2.2.1 Planejamento de Caminho

As técnicas eficientes para calcular caminhos com movimentos livres de colisão são importantes nas implementações relacionadas a multidões [40]. Os métodos de busca por áreas livres são conhecidos como planejamento de caminho (*path planning*). Os métodos de planejamento de caminhos discretos, tal como  $A^*$ , aplicados a representações do mundo em forma de malhas (*navmesh*), são robustos e simples de implementar [82]. No entanto, a qualidade da solução depende da resolução da discretização da malha. Malhas com altas resoluções executando em tempo real são computacionalmente impraticáveis [39].

As abordagens que representam o mundo com mapas de corredor (*corridor maps*) usam métodos baseados em grafo para representar os espaços livres, onde as arestas representam corredores livres de obstáculos. Cada aresta do grafo codifica um caminho. Alguns trabalhos usam representação Voronoi [33] e algoritmos de planejamento do caminho (*path planning*).

Neste mesmo contexto, recursos como malhas de navegação são amplamente utilizadas na indústria de jogos para estimar previamente a área livre, representada como uma malha de triângulos, que é usada como base nas consultas com algoritmos de *path-finding* [37]. Os geradores de planos precisam, frequentemente, refazer os planos, quando o espaço de busca é alterado, como, por exemplo, ao ser bloqueada uma saída. Nesses casos, os algoritmos de planejamento de caminhos precisam ser suficientemente robustos para serem executados em tempo real e em ambientes dinâmicos. Os métodos de planejamento visam encontrar o melhor plano, dentro da quantidade de tempo disponível [48] e [39]. Esses algoritmos usam como base o algoritmo  $D^*$  [49] que fornece garantias de solução em qualquer momento e pode reparar gradualmente sua solução para acomodar eventos dinâmicos.

### 2.2.2 Direção

A direção é a camada que interage com os algoritmos de planejamento para movimentar um agente, ao longo do seu caminho, previamente traçado, considerando as restrições de locomoção, como capacidades de rotação, limites na velocidade de deslocamento, bem como objetos dinâmicos no ambiente e outros agentes [39]. Algumas pes-

quisas usam previsões em domínio de tempo-espaço para calcular a direção em cenários dinâmicos. Essas previsões e prevenções de potenciais colisões possibilitam deixar a solução realista [60].

A técnica conhecida como RVO, Reciprocal Velocity Obstacles [2], baseia-se em velocidades para propor um método de reação buscando a prevenção de colisão loca. Para tanto utiliza a suposição de que agentes vizinhos adotarão comportamento de prevenção de colisão semelhante. Isso facilita a simulação eficiente de multidões densas sem a necessidade de comunicação explícita entre agentes.

O algoritmo ORCA, *Optimal Reciprocal Collision Avoidance*, [3], é uma evolução do algoritmo RVO. O ORCA é um método eficaz para simulações de multidão. Utiliza a metodologia de reciprocidade para evitar colisão, de maneira que cada agente tome metade da responsabilidade para evitar a colisão entre pares. Esse algoritmo assume que cada agente pode obter a distância e a velocidade em relação a seus vizinhos. Com base nessas informações, calcula-se o conjunto de velocidades restritas  $VO$ , que irão causar colisão com agentes vizinhos. Então uma velocidade, que esteja fora desta restrição ( $VO$ ) e mais próxima da velocidade desejada do agente é definida como a nova velocidade e usada no cálculo do deslocamento. Por exemplo, para dois agentes  $A$  e  $B$ , as restrições de velocidades  $VO_t A | B$  (a restrição de velocidade para  $A$  induzida por  $B$  em um intervalo de tempo  $t$ ) constituem o conjunto de todas as velocidades relativas de  $A$  em relação a  $B$  que resultará em uma colisão entre  $A$  e  $B$  em algum momento antes do tempo  $t$  [3].

Posteriormente, Golas e colegas [24] estenderam esse método e exploraram a percepção de que a prevenção de colisão exata não é necessária entre agentes, considerando que estes tenham uma certa distância, e propuseram um algoritmo de longo alcance para a prevenção de colisão. Nesse caso, cálculos são realizados para evitar colisão (de longo alcance) antecipando qualquer potencial colisão entre grupos distantes. De acordo com os autores, esse método determina eficientemente trajetórias mais suaves do que as obtidas com o modelo apresentado no trabalho de Van Den Berg [3]. A comparação com dados do mundo real demonstra que as multidões simuladas com o algoritmo exibem precisão em relação à velocidade e densidade semelhante às multidões humanas. A presente seção descreveu brevemente alguns algoritmos utilizados para determinar os deslocamentos de multidão evitando colisões. Esses algoritmos possibilitam que simuladores gerem soluções para auxiliar a tomada de decisão, como planos de evacuação e tempos de saída. A seção seguinte irá apresentar o simulador BioCrowds e a metodologia empregada para implementação de deslocamento livre de colisão presente nesse simulador. O BioCrowds foi utilizado para incorporar o modelo *Time Machine*, proposto nesta tese, bem como para a geração de resultados experimentais.

## 2.3 BioCrowds

O BioCrowds foi desenvolvido por Bicho [8], e visa simular multidões considerando características presentes na dinâmica de multidões. Em sua essência, o BioCrowds considera uma abordagem biológica de colonização do espaço proposta por Runions [69], com o intuito de simular o desenvolvimento de nervuras em folhas de plantas, e essa analogia com as plantas será relatada a seguir. Ressalta-se que esta seção está baseada no trabalho de Bicho [8]

No modelo biológico de Runions [69], a lâmina da folha é povoada por auxinas, hormônio pelo qual as nervuras competem, visando seu crescimento. Conforme o crescimento da nervura evolui, novas auxinas são distribuídas na lâmina da folha considerando o espaço ainda hábil para o seu crescimento. Esse conceito de competição entre as nervuras pelo espaço disponível para seu crescimento é simulado por Runions através de um algoritmo para colonização do espaço [69]. O modelo desenvolvido por Bicho realiza a representação explícita de espaços livres em um ambiente virtual através da utilização de um conjunto de pontos denominados marcadores. Os marcadores são tratados como recursos pelos quais os agentes competem, ou seja, só ocorrerá a movimentação se existirem marcadores livres.

Para cada agente, são alocados marcadores conforme seu espaço pessoal, visto que esse modelo emprega o conceito de proxemics, conforme foi apresentando na seção 2.1. De acordo com Bicho [8], a verificação em relação à vizinhança do agente é possível através da quantidade de marcadores relacionados ao agente. Para isso a identificação do proxemics considera o conjunto  $S$ , composto pelos  $N$  marcadores que estão mais próximos de um agente  $i$  do que de qualquer outro. Com isso é possível definir uma área denominada "área de percepção" que circunscreve o agente, permitindo-lhe conhecer os marcadores distribuídos no ambiente virtual e identificar os que estão contidos em seu espaço pessoal (proxemics). O conjunto de  $N$  marcadores  $m$  do agente  $i$  é descrito através da Equação 2.1:

$$S(i) = \{m_1, m_2, m_3 \dots m_N\}. \quad (2.1)$$

Ainda de acordo com o trabalho de Bicho [8], para cada marcador, são associados os atributos de posição e peso, sendo este último utilizado na definição do próximo passo do agente durante a simulação. A Figura 2.2 ilustra o conceito de proxemics no BioCrowds, onde os agentes são representados por pequenos quadrados coloridos dentro de uma área de percepção do espaço. Os agentes e seus marcadores são representados pela mesma cor.

O peso dos marcadores é utilizado no cálculo do próximo passo do agente  $i$ , para identificar, no conjunto  $S$ , o marcador que melhor direcionará o agente para o seu objetivo  $g$ , considerando também sua posição  $p_i$  no momento atual e a posição do marcador  $m_k$ .

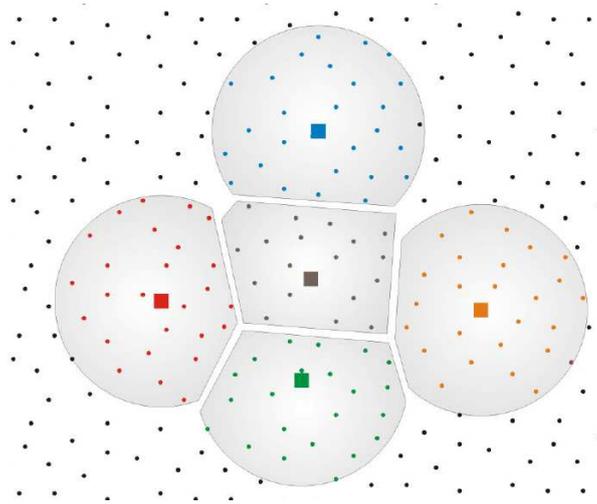


Figura 2.2 – Representação de 5 agentes e seus respectivos espaços pessoais (extraída de Lima Bicho [8])

Assim, o cálculo do peso ( $w_k$ ) de um determinado marcador, no BioCrowds [8], é realizado de acordo com a Equação 2.2:

$$w_k = \frac{f(g - p_i, m_k - p_i)}{\sum_{l=1}^N (g - p_i, m_l - p_i)}, \quad (2.2)$$

onde a função  $f$  é responsável por verificar a posição do agente em relação ao seu objetivo com a posição dos marcadores, também em relação ao objetivo. A partir do cálculo dos pesos dos marcadores, o vetor de direção, que descreve o movimento dos agentes, pode ser definido, no modelo BioCrowds, como:

$$d_i = \sum_{k=1}^N w_k (m_k - p_i). \quad (2.3)$$

Considerando os marcadores presentes no espaço pessoal, define-se o próximo passo do agente na busca de seu objetivo. O movimento de cada agente é calculado iterativamente, onde a cada iteração a posição e o vetor, que indicam o objetivo do agente, são atualizados. Nessa atualização, considera-se o conjunto de marcadores que estão mais próximos a determinado agente do que outros no espaço [8].

Apesar de o modelo BioCrowds manter características do modelo de colonização de Runions [69], algumas alterações foram necessárias na implementação do modelo de simulação de multidão, conforme relacionadas a seguir [8]:

a) Restrição do espaço das auxinas: No modelo de Runions para geração de nervuras em folhas de plantas, uma nervura pode interagir com qualquer auxina presente na lâmina da folha. No BioCrowds, o agente somente é influenciado por marcadores que se encontrem dentro de seu proxemics.

*b) Persistência das auxinas:* As auxinas são removidas da lâmina da folha quando se encontram dentro de um limiar previamente definido. Já, no modelo proposto por Lima Bicho, os marcadores são mantidos no ambiente durante toda a simulação. Os marcadores contidos no espaço pessoal do agente mais próximo a eles tornam-se temporariamente disponíveis somente ao agente em questão, sendo liberados após o seu deslocamento, quando então o processo de seleção de marcadores se repete, definindo-se um novo proxemics.

*c) Deslocamento ao destino (goal seeking):* A direção das nervuras é definida de acordo com a disponibilidade das auxinas. No BioCrowds, o deslocamento, além de considerar a disponibilidade de marcadores, também é influenciado por um objetivo a ser alcançado pelos agentes.

*d) Adequação da Velocidade:* No algoritmo de colonização do espaço, as nervuras crescem considerando uma velocidade constante. Entretanto, no modelo para simulação de multidões, as velocidades dos agentes variam considerando a disponibilidade de espaço e suas velocidades máximas.

Com base no objetivo a ser atingido e também nos marcadores integrantes do proxemics do agente, é possível efetuar o cálculo que irá identificar a posição do agente no próximo passo, gerando os deslocamentos e a movimentação dos agentes. Mais detalhes e informações sobre o BioCrowds podem ser encontradas em [7].

### 3. TRABALHOS RELACIONADOS

Este capítulo contempla o estado da arte sobre os trabalhos correlacionados com os temas desta pesquisa, tais como como Simulação de Multidão, *Dead Reckoning* e Complexidade de Ambientes. Trabalhos na linha de pesquisa de simulação de multidão serão discutidos para contextualizar o presente modelo no estado da arte. Inicialmente, estimativas sobre o futuro são realizadas usando *Dead Reckoning*, tornando-se relevante uma revisão de trabalhos realizados com essa técnica. Posteriormente, o modelo deve considerar informações do ambiente. Desta forma, trabalhos sobre complexidade de ambientes também serão citados.

#### 3.1 Simulação de Multidões

A área de simulação de multidões vem conquistando resultados promissores nos últimos anos e com aplicações em diferentes propósitos, tais como segurança [14, 34], entretenimento [32] e psicologia [52]. As principais abordagens de simulação serão apresentadas nesta seção.

Segundo Thalmann e Musse [76], é possível distinguir dois principais aspectos na simulação de multidões. A primeiro está focado no realismo das regras de comportamento, utilizando visualizações 2D para auxiliar a compreensão dos resultados de simuladores de evacuação, sem atentar para a aparência dos atores. Em muitos casos, os membros da multidão apresentam uma representação simples, usualmente definidos como pontos coloridos. Nesse enfoque, o principal objetivo é validar quantitativamente os resultados obtidos de simulações, comparando-os aos dados coletados de multidões reais, adquiridos através de observações humanas ou por algum método de visão computacional [79].

O segundo aspecto é a visualização em alta qualidade, onde o realismo do modelo comportamental não é o objetivo principal, mas sim um resultado visual convincente. A ênfase nessa área está no processo de renderização, no movimento dos personagens e nas suas representações tridimensionais texturizadas. Nesse contexto, os modelos comportamentais não objetivam apresentar quantitativamente bons resultados, mas facilitar o trabalho de produção dos animadores e permitir que os humanos virtuais reajam a estímulos em aplicações interativas.

Nos últimos anos, a tendência tem sido a convergência de ambas as áreas, onde sistemas orientados à visualização estão incorporando melhores modelos comportamen-

tais para facilitar a criação de animações convincentes, enquanto que sistemas orientados ao comportamento estão incorporando melhores visualizações, principalmente no domínio dos simuladores de evacuação [76]. Até o momento, muitas metodologias de simulação de multidão foram desenvolvidas para modelar o movimento da multidão, e podem ser classificadas como macroscópicas e microscópicas. Segundo Thalmann e Musse [76] modelos macroscópicos analisam a multidão como um todo e características individuais não são consideradas. Esses modelos normalmente são aplicados a grandes multidões onde o principal interesse é conhecer o comportamento coletivo. Em contrapartida, os modelos microscópicos focam nos comportamentos individuais das pessoas que compõem a multidão.

Devido ao grande número de trabalhos propostos nas áreas citadas e visto que a contribuição desta tese não consiste em desenvolver um método para controlar multidões, serão apresentados brevemente alguns trabalhos relacionados aos modelos Macroscópicos e Microscópicos.

### 3.1.1 Modelos Macroscópicos

Os modelos macroscópicos são voltados aos sistemas de partículas, neste caso, a individualidade dos elementos não é o objetivo dos trabalhos propostos. Esses modelos definem as interações dos elementos de maneira coletiva, baseados em regras e em leis da mecânica dos fluidos.

Os trabalhos dos autores brevemente descritos a seguir, representam essa categoria. Reynolds [68] propõe uma hierarquia de três níveis de abstração para modelar os comportamentos dos personagens: o nível de seleção da ação, o nível de manobra e o nível de locomoção. Em Guy [25], os autores apresentam um modelo de descritores de personalidade que se relaciona com parâmetros de multidão, a fim de simular humanos virtuais heterogêneos em grande escala.

Narain [56] descreve um modelo para representar agentes como um sistema contínuo, a fim de tratar situações de colisão em alta densidade de personagens em tempo real. Também é possível utilizar, neste contexto, as técnicas de PSO (*Particle Swarm Optimization*) com o objetivo de melhor considerar o espaço de busca das soluções de simulação [41].

Dutra e colegas [21] utilizaram a abordagem macroscópica com o propósito de reduzir custo computacional, em simulações com grande número de agentes, e preservar o realismo. Com esse objetivo os pesquisadores propuseram um modelo que combina Campo Potencial, técnica desenvolvida para guiar agentes com objetivos comuns [81] e RVO (Reciprocal Velocity Obstacle), método para evitar colisão restringindo as velocidades [80]. O modelo unifica, temporariamente, os grupos que possuem área de transição comum (grupos com o mesmo sentido). Os grupos são guiados por Campos Multipotenci-

ais, responsáveis pela navegação global, e auxiliando os agentes a evitarem colisões com o cenário, enquanto que a RVO trata as colisões entre agentes.

### 3.1.2 Modelos Microscópicos

Os modelos microscópicos referem-se às abordagens baseadas em agentes, onde o coletivo é uma característica emergente da atuação individual. Para definir a individualidade dos elementos na simulação, são utilizados conjuntos de regras e leis físicas que permitem representar, de maneira abstrata, a “psicologia” dos elementos modelados. Os autores Tu e Terzopoulos [74] propuseram um *framework* para simulação de ecossistemas com mínima intervenção do usuário. Musse e Thalmann propuseram um modelo hierárquico baseado em grupos para simulação de multidões em tempo real [54]. O modelo permite definir comportamentos de indivíduos (humanos virtuais) e de grupos em diferentes níveis de autonomia. Ulicny e Thalmann [79] propuseram uma arquitetura multicamadas para modelar comportamentos autônomos de humanos virtuais em ambientes interativos. Um modelo para representar características individuais e verificar o impacto das mesmas em simulações de multidões durante situações de emergência foi projetado por Braun e colaboradores [12].

O principal foco dos modelos baseados em agentes é incorporar comportamentos individuais. Nessa abordagem o interesse está em representar, de maneira realística, as decisões individuais que refletem o coletivo. As técnicas de movimentação e prevenção de colisão são integradas aos modelos de simulação com este propósito. No entanto, esses métodos, como o ORCA, apresentado na Seção 2.2, requerem o processamento de vários cálculos, acarretando um alto custo computacional. Um dos temas recorrentes da literatura são os artifícios para reduzir os custos inerentes aos métodos para prevenção de colisão. Algumas pesquisas relacionadas serão brevemente discutidas a seguir.

### 3.1.3 Custo Computacional

A infinidade de combinações e cálculos, característicos dos processos de prevenção de colisão em multidão, demandam um alto custo computacional. Com o intuito de reduzir esse custo, estudos recentes propuseram o uso de técnicas que envolvem o Nível de Detalhamento (*Level Of Detail - LODs*), . Para isso, consideram o ponto de vista da câmera e a relevância de um determinado objeto na simulação. De acordo com Hardy e colegas [29], *LOD* é uma técnica utilizada para renderizar personagem/objetos distantes do observador/câmera com menor detalhamento, reduzindo os custos de processamento.

Essa técnica é aplicada principalmente quando os detalhes de um objeto ou parte de uma cena não são visíveis (ou são imperceptíveis).

A abordagem de ocultar detalhes ou objetos na renderização, a fim de minimizar os cálculos para evitar a colisão, é apresentada na pesquisa de Guy e colaboradores [26], que estendem a noção de RVO para a navegação livre de colisão em um algoritmo paralelizado. Essa estratégia também foi utilizada por Pettre e seus colaboradores que propuseram o uso de *LOD* para melhorar o desempenho e o tempo de processamento de prevenção de colisões [65, 66].

Paris et al. [59] propõem um modelo usando LOD que permite que os jogos apresentem grandes multidões em tempo real com comportamento inteligente. Os autores avaliam um modelo em situações necessárias, como os desvios de obstáculos. Outro trabalho voltado para a área de jogos é demonstrado em Dal Bianco e colaboradores [20], que visa desativar o método para prevenção de colisão durante a simulação e realizar ajustes voltados à redução de velocidade que seja coerente com a estimativa no tempo. Os autores utilizam um banco de dados para treinamento do modelo, e em tempo de execução, dado um instante da simulação para o qual se deseja prever o estado futuro, há uma busca no banco de dados, a fim de identificar uma simulação similar. A partir disso, as reduções são informadas permitindo aplicar os ajustes de velocidade nas posições futuras, sem fazer cálculos de colisão.

No âmbito de pesquisas recentes, cabe citar as temáticas voltadas para modelar comportamento humano, consideradas essenciais quando se trata de manter o realismo [47]. Deste modo, os modelos baseados em agentes são estendidos incluindo-se variáveis de personalidade que representam fatores fisiológicos e psicológicos observados nas pessoas. Neste contexto, os trabalhos [11, 61, 75] apresentam métodos para criar comportamentos heterogêneos motivados por diferentes estados mentais, diferentes ambientes virtuais ou por suas características comportamentais e físicas. Apesar destas evoluções no campo comportamental, sabe-se que as emoções não são constantes, mas dependem da personalidade, do humor, dos agentes vizinhos e dos dados ambientais. Desta forma, as emoções podem variar no tempo e evoluir durante a simulação [10]. Diante disso, surgiram pesquisas recentes, relacionadas a contágio de emoções. Borges e colaboradores [10] apresentam um modelo que considera três emoções: tristeza, raiva e alegria. Esse modelo é baseado em parâmetros predeterminados por estudos da área da psicologia, em situações que investigam e testam o impacto de um agente triste ou alegre na multidão.

### **3.2 Dead-Reckoning**

A posição de pessoas ou personagens em sequências de vídeos ou em simulações é considerada uma informação valiosa, sendo usada em muitas aplicações tais como

segurança, logística e entretenimento [36]. As posições dos personagens são a base para a técnica *Dead-Reckoning*, que é definida como um processo para estimar a posição aproximada de qualquer objeto, baseado nas informações do passado [13, 71]. Com a expansão do uso de dispositivos móveis surgiu o termo *Pedestrian Dead Reckoning* tendo o mesmo princípio da técnica precursora, mas especificamente usada para inferir a posição de pessoas. Neste caso, o foco é estimar a posição das pessoas onde o *Global Positioning System* (GPS) não seja acessível ou suficientemente preciso, como em elevadores, pontes e áreas internas de edifícios [72].

Recentemente as pesquisas utilizam a técnica PDR embarcada em sensores para o rastreamento de pessoas em aplicações de assistência a usuários com necessidades especiais, tais como idosos, crianças e deficientes visuais [50]. Além disso, essa técnica é amplamente utilizada para auxiliar na atualização das posições e movimentação de avatares em jogos multiplayer distribuídos. Usando como base as informações visíveis nos mapas virtuais, os jogadores decidem as próximas ações, tais como trocar o estado do seu avatar, esconder-se ou atacar os inimigos. A atualização das posições para todos os jogadores conectados (clientes) pode ser feita diretamente entre jogadores ou através de servidores. Nestes ambientes, os jogadores mantêm uma visão consistente das posições uns dos outros através da troca constante de mensagens. As mensagens de atualização, além de sofrerem alguns atrasos de entrega, representam uma sobrecarga na rede [83]. Neste caso, em jogos virtuais, um problema típico é estimar a posição de personagens virtuais em sucessivas taxas de atualização de *frames*.

Nessa situação, as variáveis chaves usadas em *PDR* são relacionadas à cinemática, tais como a última posição do personagem  $x_t$ , a velocidade  $v_t$  e a aceleração  $a_t$ . Onde  $t$  representa o tempo. Informações extras, como orientação e velocidade angular, também auxiliam na estimativa de dados no tempo futuro. As estimativas das trajetórias dos personagens dependem das equações do movimento, mais especificamente, da segunda lei de Newton, que analisa posição, velocidade e aceleração usando equações que relacionam essas grandezas, conforme se segue:

$$a_{t+\Delta t} = x_t + v_t \Delta t + \frac{1}{a_t} \Delta t^2 \quad (3.1)$$

Onde a posição futura do objeto  $t + \Delta t$  é determinada por sua posição inicial, velocidade inicial e aceleração.

Em Computação Gráfica, o uso desta técnica ocorre há alguns anos. O trabalho de Tolga e colaboradores [13] ilustra a aplicabilidade da técnica em ambientes virtuais onde avatares (entidade que representa os usuários no mundo virtual) interagem, e colaboram entre si. O objetivo do estudo é estimar a movimentação dos avatares diminuindo o tráfego de informações na rede [13]. Corroborando com Tolga [13], o trabalho de Yahyavi e

demais autores [83] objetiva estimar a movimentação em jogos multiplayer. Levando em consideração possíveis objetivos a fim de estimar as próximas posições.

A técnica *Dead Reckoning* foi utilizada juntamente com a heurística Colônia de Formigas (*AntReckonig*), onde os possíveis pontos de interesse dos jogadores recebem feromônios. Esses pontos exercem atrações diferenciadas sobre os personagens, o PDR é usado para estimar movimentos dos personagens nesse ambiente.

A integração das técnicas PDR em simuladores de multidão parece factível. No entanto, o comportamento de multidões é afetado pelas pessoas que compartilham o mesmo espaço, e também pelo ambiente da simulação, com objetos e restrições de espaço.

A próxima seção aborda alguns trabalhos relacionados a complexidade de ambientes.

### 3.3 Complexidade de ambientes

A evolução das técnicas de modelagem e renderização possibilitou a geração de cenários virtuais sofisticados equivalendo-se aos ambientes físicos reais [64]. Atrelada a essa evolução, as recentes técnicas de simulação de multidão possibilitam preencher os cenários virtuais com milhares de agentes. Diante disso, surgiu uma nova frente de pesquisa, voltada a ambientes virtuais, possibilitando integrar cenários complexos com as técnicas de navegação para a movimentação de pessoas, representadas por agentes ou personagens virtuais, nos mais variados ambientes [5].

Outro interesse das pesquisas direcionadas aos cenários virtuais é a possibilidade de identificar como a configuração do espaço impacta no fluxo das pessoas, por exemplo, como o número, a localização e a dimensão de objetos presentes no ambiente podem influenciar positivamente o momento de uma evacuação. O trabalho de Berseth e colaboradores [5] vem ao encontro dessa abordagem. Os autores desenvolveram um modelo capaz de estimar o nível de complexidade de ambientes virtuais com base em informações do cenário e dos agentes que nele são simulados. O estudo contempla uma análise estatística do cenário e produz um conjunto de características que representam as interações entre agentes e obstáculos que possam vir a ocorrer durante a simulação. O método foi avaliado empregando cenários dos jogos *Starcraft*, *DragonAge* e *Warcraft*.

Berseth e colegas [6] definem um cenário  $s$  como sendo uma configuração específica de obstáculos e agentes de um ambiente, dada como  $s = \langle O, A \rangle$ . Um obstáculo  $o \in O$  é determinado por uma posição particular  $(x_o)$  no ambiente, e tem um formato de um prisma de seção retangular ou de um cilindro. Um agente  $a \in A$  é definido como  $a = \langle x, r, g \rangle$ , onde  $x$ ,  $r$  e  $g$  são posição, raio e destino de um agente. Este estudo demonstrou como elementos estruturais como portas e pilares podem ser distribuídos para facilitar o fluxo de pessoas.

Os autores realizaram simulações com várias configurações de cenário (praticando fluxos uni, bi e quadridirecionais). Para cada cenário, considerarem-se cinco distribuições de pilares (0, 1, 2, 3 e 4) e o tempo de evacuação em cada situação foram comparados. Os autores concluíram que a configuração com quatro pilares melhora o fluxo entre as pessoas. A Figura 3.1 apresenta as capturas de tela na ordem de ocorrência de dois cenários semelhantes com dois grupos de agentes caminhando em direções opostas. Ao se adicionarem quatro pilares (conforme imagens inferiores), melhorou-se o fluxo para ambos os grupos em comparação com o caso sem pilares (topo), bem como diminuiu-se o tempo de evacuação.

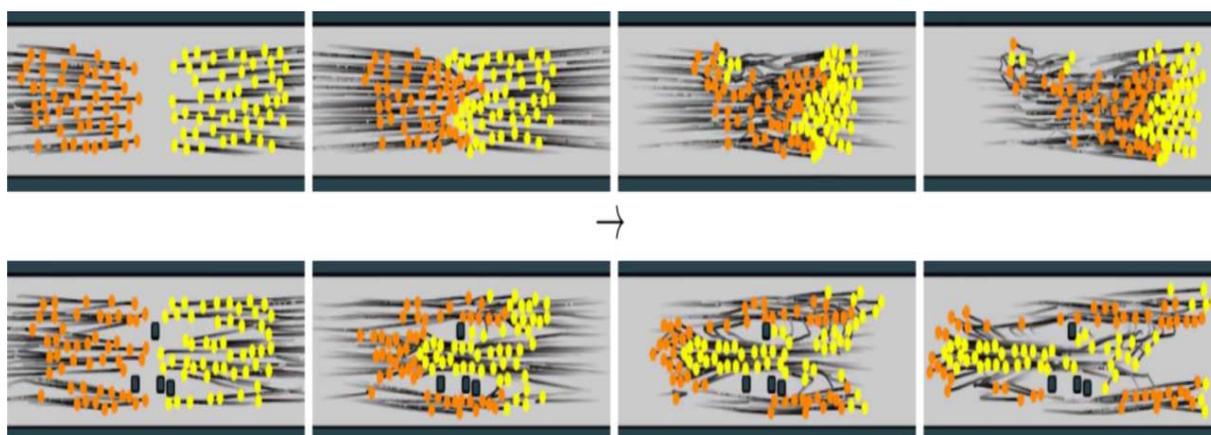


Figura 3.1 – Resultados obtidos por Berseth e colegas [6]

O trabalho de Perkins [64] apresenta uma técnica para analisar os layouts para facilitar a visibilidade e a acessibilidade em jogos. A pesquisa proposta por Jiang e demais autores [35] aborda a problemática envolvendo simulações de multidão em ambientes complexos com comportamentos plausíveis a esses ambientes. Para isso, três etapas são apresentadas: *i)* emprego de artifício para discretizar a estrutura do ambiente, ajudando, assim, a organizar e a simular multidões em amplos e complexos cenários; *ii)* inclusão de zonas de desconforto no entorno dos obstáculos para manter uma distância psicologicamente plausível entre as pessoas e os obstáculos, possibilitando trajetórias mais suaves quando as pessoas se movem em torno desses obstáculos; e *iii)* desenvolvimento de uma técnica para conversão de densidade, ou seja, a densidade é afetada dinamicamente por cada indivíduo, podendo ser adaptada a diferentes resoluções. Os experimentos demonstram que o método foi eficiente para simulações de multidão em ambientes complexos e dinâmicos.

O trabalho de Kapadia e colaboradores [38] apresenta um framework para planejar a navegação de vários personagens em ambientes virtuais amplos, complexos e dinâmicos. Nesse trabalho, o problema original de navegação é decomposto em um conjunto de problemas menores, chamados domínio do problema. Essa distribuição dos domínios do problema é ilustrada na Figura 3.2. A Figura 3.2 (a) apresenta o cenário e ilustra a confi-

guração do ambiente físico no momento inicial da simulação. Em seguida, a Figura 3.2 (b) ilustra o resultado de um algoritmo de *path planning* usado para gerar as possíveis trajetórias, considerando somente a geometria estática do ambiente. Na sequência, a Figura 3.2 (c) ilustra um algoritmo de *path planning* executado para identificar a interação com objetos dinâmicos e atualizar a trajetória. A Figura 3.2 (d) apresenta o cenário dividido em *grids*. Finalmente, a Figura 3.2 (e) apresenta a última etapa onde as colisões entre agentes são incluídas nas trajetórias.

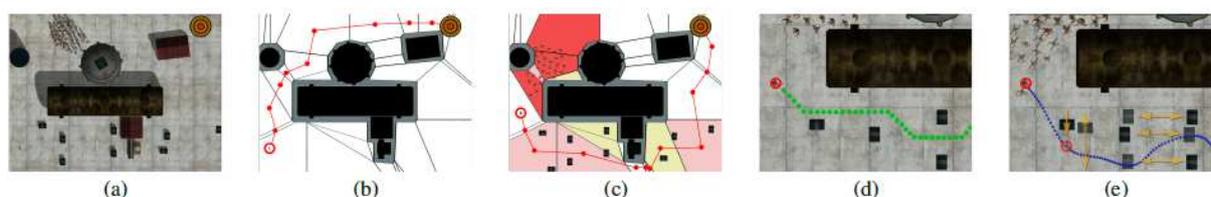


Figura 3.2 – Esquema dos diferentes domínios do problema que foram propostos em Kapadia et al. [38]

### 3.4 Contextualização da proposta no Estado da Arte

Após a apresentação das temáticas abrangendo multidão, comportamento de multidão e a descrição do modelo de simulação BioCrowds presentes no Capítulo 2, bem como as abordagens desse Capítulo, permitem realizar a contextualização dessa tese no Estado da Arte das técnicas correlacionadas.

Inicialmente aponta-se que as pesquisas relacionadas à simulação de multidão evoluíram no sentido de apresentar algoritmos eficientes para evitar colisão (com outros indivíduos e obstáculos) [53, 76, 10], bem como preencher e renderizar cenários virtuais com milhares de agentes e movimentá-los com comportamentos realísticos [6, 61]. Além disso, é possível simular multidões em cenários virtuais tão sofisticados quanto os ambientes reais [5, 35, 38, 62] e identificar os planos de evacuação ideais a partir de pontos de decisão capazes de controlar os agentes, selecionar rotas específicas e sugerir roteiros de evacuação com estimativa de tempo de abandono [14].

Considerando o estado da arte, este trabalho de doutorado tem como foco principal propor uma abordagem onde seja possível a análise de uma multidão a fim de estimar seu comportamento em um período futuro, sem a necessidade da simulação de todo o intervalo de tempo. Para realizar a estimativa das posições no tempo futuro, além de considerar todas as questões do comportamento de multidão, será proposta uma estimativa inicial das posições a partir da técnica *Pedestrian Dead Reckoning*. Como essa técnica apresenta uma estimativa baseada no deslocamento em linha reta, assume-se ser necessário identificar o

impacto das interações com outras pessoas, bem como o impacto da complexidade do ambiente e realizar ajustes no deslocamento oriundo de PDR.

Além das questões supracitadas, devem-se considerar fatores peculiares do comportamento de multidão (estratégias de mínimo esforço, deslocar-se evitando colisão, formação de *lanes*, entre outros). Para tanto, a emprega-se o modelo BioCrowds descrito no Capítulo 2. A justificativa para utilização do BioCrowds é dedicar-se a estender um modelo que seja validado e avaliado para prover a predição de comportamentos em tempos futuros. Apesar de existirem técnicas para predição de posição de pedestres [72, 50], se trata de estimativas que necessitam de aprimoramento para se estimar posições de multidões em ambientes complexos. Diante disso, considera-se a predição em tempo futuro de multidão como um problema ainda em aberto.

O próximo capítulo apresenta as principais etapas idealizadas para resolver o problema apresentado nessa tese.

## 4. MODELO PROPOSTO PARA PREDIÇÃO DE COMPORTAMENTO FUTURO DE MULTIDÃO

Este capítulo apresenta o modelo proposto para predição de comportamento de multidão, denominado *Time Machine*. A *Time Machine* foi planejada para prever as futuras posições de uma multidão empregando estimativas oriundas da técnica *PDR* e posteriormente essa estimativa foi ajustada considerando as interações entre pessoas e a complexidade do ambiente.

Neste caso, algumas informações são necessárias, como as posições, as velocidades e os destinos dos agentes, bem como as informações do ambiente referentes ao, número de obstáculos, às áreas dos obstáculos e à ocorrência ou não de eventos. A partir desses dados, a metodologia proposta considera essas características como parâmetros que afetam a velocidade e a direção dos agentes no tempo futuro, estimando como consequência as futuras posições. Assim, o método permite avançar do instante  $t$  (por exemplo, instante em que a simulação foi pausada) até o instante futuro  $t + \Delta t$ . Note que, o foco dessa metodologia foi avançar a simulação preservando os atributos (velocidade e direção) e mantendo a acurácia em relação à simulação contínua.

A Tabela 4.1 apresenta a notação utilizada nas equações no texto, bem como uma breve descrição de cada símbolo.

Tabela 4.1 – Descrição da notação. Símbolos com seta ( $\vec{\quad}$ ) representam vetores, barras ( $\|\quad\|$ ) indicam módulo e demais notações representam variáveis escalares

Símbolo	Descrição
$t$	Frame de Pause da simulação e início do avanço de tempo
$t + \Delta t$	Duração do avanço de tempo
$t_1$	Finalização do avanço de tempo
$t_n$	Instante de análises ( $t_1$ ; $t_2$ e $t_3$ )
$\vec{X}$	Posição de um agente
$\vec{g}$	Destino de um agente
$s$	Velocidade de um agente
$t_k$	Instante de início de evento
$\tau_k$	Tipo de evento
$tn$	Instante de ocorrência de eventos

A seguir será detalhas as etapas do modelo. Além disso, será relatado uma extensão modelo para suportar a inclusão de eventos durante o avanço de tempo.

## 4.1 Etapas do Modelo *Time Machine*

Para atingir o objetivo ao qual o modelo se propõem foi necessário o processamento das seguintes etapas:

1. Calcular a posição dos agentes em um determinado tempo futuro, dado como  $t + \Delta t$ , empregando o método *Pedestrian Dead Reckoning*, que utiliza as informações da multidão no tempo  $t$ ;
2. Identificar como a presença de outros agentes/pessoas e as interações entre eles afetam a velocidade de cada indivíduo;
3. Analisar o impacto da complexidade do ambiente na direção e na velocidade das pessoas;
4. Estimar as posições dos agentes no tempo  $t + \Delta t$ , integrando as informações sobre o posicionamento (oriundas da técnica PDR), sobre as interações entre indivíduos, e sobre a complexidade do ambiente.

Estas etapas são executadas para todos os agentes que fazem parte da multidão. A última etapa consiste no posicionamento dos agentes no BioCrowds, evitando que os agentes sejam posicionados na área interna de obstáculos ou uns sobre os outros. A seguir será detalhada cada etapa do modelo.

### 4.1.1 Estimar a posição prévia dos agentes

Essa etapa inicial do método *TM* com estimativas usa a sistemática do *PDR* baseado no emprego da Cinemática. Detalhes desta técnica bem como trabalhos relacionados estão apresentado no Capítulo 3. O objetivo é obter uma estimativa das futuras posições dos agentes considerando somente a Física. Para encontrar a estimativa da futura posição de um agente  $i$  no *frame*  $t + \Delta t$ , onde  $\Delta t$  é o tempo de avanço no tempo, utiliza-se as seguintes informações:

1. A posição atual do agente  $i$  no *frame*(atual)  $t$ , denotado por  $\vec{X}_t^i = (x_t^i, y_t^i, z_t^i)$ ;
2. o objetivo do agente  $\vec{g}^i = (g_x^i, g_y^i, g_z^i)$ ; e
3. a velocidade desejada  $s^i$ .

De posse destas informações a posição estimada do agente  $i$  no *frame* (futuro)  $t + \Delta t$  é descrita pela Equação 4.1:

$$\vec{pdr}_{t+\Delta t}^i = \vec{X}_t^i + \left( s^i \frac{\vec{g}^i}{\|\vec{g}^i\|} \right) (\Delta t). \quad (4.1)$$

O método *PDR* gera um boa estimativa da futura posição, mas está suscetível a erros devido a fatores como variação de velocidade, presença de outros agentes e obstáculos na simulação, visto que o método não considera nenhum destes aspectos. Além disso, no BioCrowds a movimentação dos agentes está associada à distribuição de marcadores. No caso, menor densidade de marcadores geram movimentos menos parecidos com linhas retas. Essa análise é apresentada em [8] e também em experimentos que serão apresentados na seção 5.2.1.

A seguir apresenta-se um estudo de caso contendo apenas um agente. Os dados de entrada para a simulação são apresentados na Tabela 4.2. Nesse caso específico, o agente é simulado do *frame* 1 ao *frame* 100, quando a simulação é pausada e os dados são coletados. Importante salientar que o *frame* de retorno 700 é de escolha do usuário e pode representar um *frame* antes do qual o agente já tenha chegado ao seu destino.

Tabela 4.2 – Dados da simulação com um agente

Dados	
Frame $t$	100
Posição no frame $t$	(5,453;20,181;0,0)
Velocidade $s$	0,046/frame
Objetivo $\vec{g}$	(38,039;19,979;0,0)
Frame $t + \Delta t$	700

Para medir o erro do *PDR*, primeiramente realizou-se a simulação com um agente, em um cenário sem obstáculos e um fator de distância mínima entre marcadores de 0,175. Baseado nos dados da Tabela 4.2, simulou-se um agente em um ambiente sem obstáculos, e mediu-se o erro presente na estimativa do *PDR* (executando a Equação 4.1) e comparou-se com o BioCrowds simulado. Mais precisamente, o erro obtido da simulação de um agente em comparação com o resultante do *PDR* é dado por (Equação 4.2):

$$Error_{t \rightarrow t+\Delta t}^i = \frac{d(\vec{X}_{t+\Delta t}^i, \vec{pdr}_{t+\Delta t}^i)}{d(\vec{X}_t^i, \vec{X}_{t+\Delta t}^i)}, \quad (4.2)$$

onde  $\vec{X}_t^i$  é a posição do agente  $i$  no *frame*  $t$  (quando a simulação é pausada),  $\vec{pdr}_{t+\Delta t}^i$  e  $\vec{X}_{t+\Delta t}^i$  são posições do agente  $i$  no *frame*  $t + \Delta t$  obtidas na TM e na simulação (contínua), respectivamente. Para as simulações realizadas o erro foi de 0,03467 em 600 frames. Posteriormente realizaram-se alguns testes com diferentes distribuições de marcadores com o intuito de verificar o impacto do próprio BioCrowds no erro obtido. Assim, o valor de distân-

cia mínima de marcadores que apresentou o menor erro foi de 0,06. Repetindo a simulação com os mesmos dados de entrada da Tabela 4.2 em um cenário sem obstáculo, com um agente e fator de distância mínima entre marcadores de 0,06, nessa situação o erro obtido foi 0,0013 em 600 frames.

#### 4.1.2 Analisar a Complexidade do Ambiente

Embora seja importante iniciar com uma boa estimativa, como é o caso do *PDR*, também é relevante considerar a complexidade do ambiente no modelo da *time machine*. Evidentemente, área livre, bem como o número e a dimensão de obstáculos têm impacto no fluxo de pedestres. Para tanto, o modelo propõe a função de complexidade do ambiente *EC*, que foi modelada a partir dos espaços livres para a movimentação da multidão. Nesse caso, consideraram-se o número de agentes e obstáculos, e o espaço necessário para comportá-los. Incluiu-se uma constante  $0 < \alpha < 1$  que representa o peso associado ao número de obstáculos. Efetivamente,  $\alpha$  define quanto peso deve ser dado para o número de objetos ponderando sua dimensão, com o intuito de diferenciar um obstáculo grande de vários obstáculos pequenos. Assim, a equação para complexidade *EC* foi definida como:

$$EC = \min\left\{1, \frac{n_a A_a + \alpha n_o}{A_w - A_o}\right\}, \quad (4.3)$$

onde  $n_a$  representa o total de agentes na simulação,  $A_a$  é a área de um agente (considerou-se a área como o espaço máximo que uma pessoa utiliza, neste caso um diâmetro de 0,456m) e  $n_o$  indica o número de obstáculos presentes no ambiente simulado. Da mesma forma,  $A_w$  representa a área total do ambiente e  $A_o$  é a soma da área de todos os obstáculos. Caso, o número de agentes ou área ocupada pelos obstáculos seja muito grande e não exista espaço suficiente para permitir as movimentações individuais, então *EC* assume o valor de 1 e movimentos não são permitidos. A Equação 4.4 apresenta uma penalização, ou seja, um atraso na posição estimada de cada agente, em relação a *PDR*, apresentada na Equação 4.1:

$$\begin{aligned} \vec{pdr}'_{t+\Delta t}^i &= \vec{pdr}'_{t+\Delta t}^i - \left( s^i \frac{\vec{g}^i}{\|\vec{g}^i\|} \right) EC \Delta t \\ &= \vec{X}_t^i + \left( s^i \frac{\vec{g}^i}{\|\vec{g}^i\|} \right) (1 - EC) \Delta t. \end{aligned} \quad (4.4)$$

A Equação 4.4 apresenta o método *TM* considerando o *PDR* e a complexidade do ambiente. Resultados serão discutidos no Capítulo 5. A próxima seção apresenta a estimativa realizada em função da interação presente entre as pessoas.

### 4.1.3 Calcular a Interação entre as Pessoas

Em simulações de multidão, é conhecido o forte impacto que as interações entre as pessoas têm no posicionamento e nas velocidades desejadas dos indivíduos. Isso explica a importância dada aos métodos de menor esforço e prevenção de colisão [76]. Como exemplos dessas interações podem-se citar, o encontro com grupo de pessoas vindo em direção oposta, as mudanças de direção e o impacto no fluxo da multidão. Esses efeitos ocorrem nas tentativas de evitar colisão e podem produzir perturbação ou interferência nas velocidades desejadas dos agentes. Essa interferência depende de várias características da multidão, tais como a direção do fluxo, a variabilidade da velocidade desejada e a densidade local. Devido à complexidade na simulação de multidões densas, utilizou-se uma abordagem estocástica para mensurar como a interferência, proveniente das interações entre agentes, impacta a velocidade dos indivíduos.

Efetivamente, realizaram-se diversos pares de simulações, variando o número de agentes  $n_a$ , a média e o desvio padrão da velocidade desejada. Cada par de simulações corresponde a uma simulação com  $n_a$  agentes movendo-se com fluxo unidirecional e outra simulação com  $2n_a$  agentes com fluxo bidirecional, mas mantendo as mesmas configurações do fluxo unidirecional, tais como identificadores dos agentes (para comparação), velocidades desejadas, ponto de início e ponto de destino. A Figura 4.1 apresenta um dos pares de simulações analisados. As setas cinzas indicam o sentido da movimentação. As imagens foram salvas no mesmo *frame*. Como pode-se observar, os agentes da simulação com fluxo bidirecional (abaixo) e, da esquerda para a direita, apresentam o mesmo identificador e posição da simulação com fluxo unidirecional.

Para medir a interferência causada pelo fluxo contrário na movimentação de determinado agente  $i$ , computou-se o deslocamento deste agente a cada janela de tempo  $W = 2$  segundos, em ambas as simulações para cada par de simulações unidirecional e bidirecional. O deslocamento do agente  $i$  no fluxo unidirecional foi identificado como  $\Delta\vec{X}_{iU}$ , já o deslocamento do mesmo agente no fluxo bidirecional foi identificado como  $\Delta\vec{X}_{iB}$ . O impacto na velocidade de determinado agente  $i$  causado pela interferência do fluxo contrário é dado por:

$$\Delta\vec{v}_i = \frac{\Delta\vec{X}_{iU} - \Delta\vec{X}_{iB}}{W}. \quad (4.5)$$

O valor de  $\Delta\vec{v}_i$  foi calculado para cada agente (com referência em fluxos unidirecional e bidirecional) nos diferentes pares de simulação. Para os referidos agentes, associou-se um valor correspondente à densidade local. A qual, foi calculada considerando o número de agentes presentes a cada região de  $4\text{m}^2$ , com o agente  $i$  no centro. Assim, agruparam-se os valores de  $\Delta\vec{v}_i$  em função de valores da densidade local  $\rho \in \{0,25; 0,50; \dots, 2,5\}$  agentes/ $\text{m}^2$ . As distribuições de variação de velocidade dos pares de simulações gerados

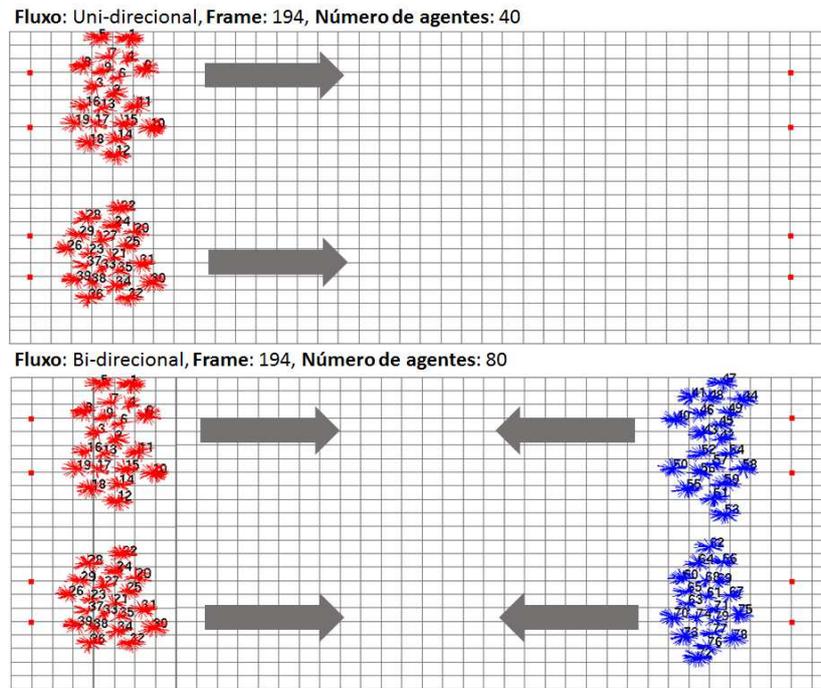


Figura 4.1 – Exemplo de pares de simulação empregados no cálculo do atrapalhamento

no BioCrowds para os oito primeiros valores de  $\rho$  ( $\rho = 0,25$  a  $\rho = 1,25$  agentes/m<sup>2</sup>) são apresentadas nas colunas azul-escuras dos histogramas na Figura 4.2.

Após essa análise, constatou-se que a distribuição observada no BioCrowds é semelhante à distribuição de Weibull [45], dada pela Equação 4.6:

$$f(x) = \frac{b}{a} \left(\frac{x}{a}\right)^{b-1} \exp \left[ - \left(\frac{x}{a}\right)^b \right]. \quad (4.6)$$

Empregou-se uma estimativa de probabilidade máxima, a fim de encontrar os valores de  $a$  e  $b$  que melhor se ajustassem à distribuição Weibull. Depois deste processo, arquivaram-se 10 distribuições Weibull  $f(\Delta \vec{v} | \rho)$ , uma para cada valor de densidade local  $\rho$ .

Após calculadas as distribuições de redução de velocidade, para determinar a redução de velocidade  $IP_t^i$ , de um agente  $i$ , de acordo com a densidade local  $\rho_t^i$  no frame  $t$ , gera-se, aleatoriamente, o valor de  $IP_t^i$  usando o arquivo de distribuição Weibull, correspondente à densidade local, dado pela Equação 4.7:

$$IP_t^i = W(\rho_t^i, t). \quad (4.7)$$

O valor de  $IP_t^i$  é integrado na Equação 4.4 e gera a posição final do agente  $i$  no modelo  $TM$ , isto é,  $\vec{t}m_{t+\Delta t}^i$  no tempo futuro  $t + \Delta t$ , conforme Equação 4.8:

$$\vec{t}m_{t+\Delta t}^i = \rho \vec{d}r_{t+\Delta t}^i - IP_t^i \frac{\vec{g}^i}{\|\vec{g}^i\|} \Delta t. \quad (4.8)$$

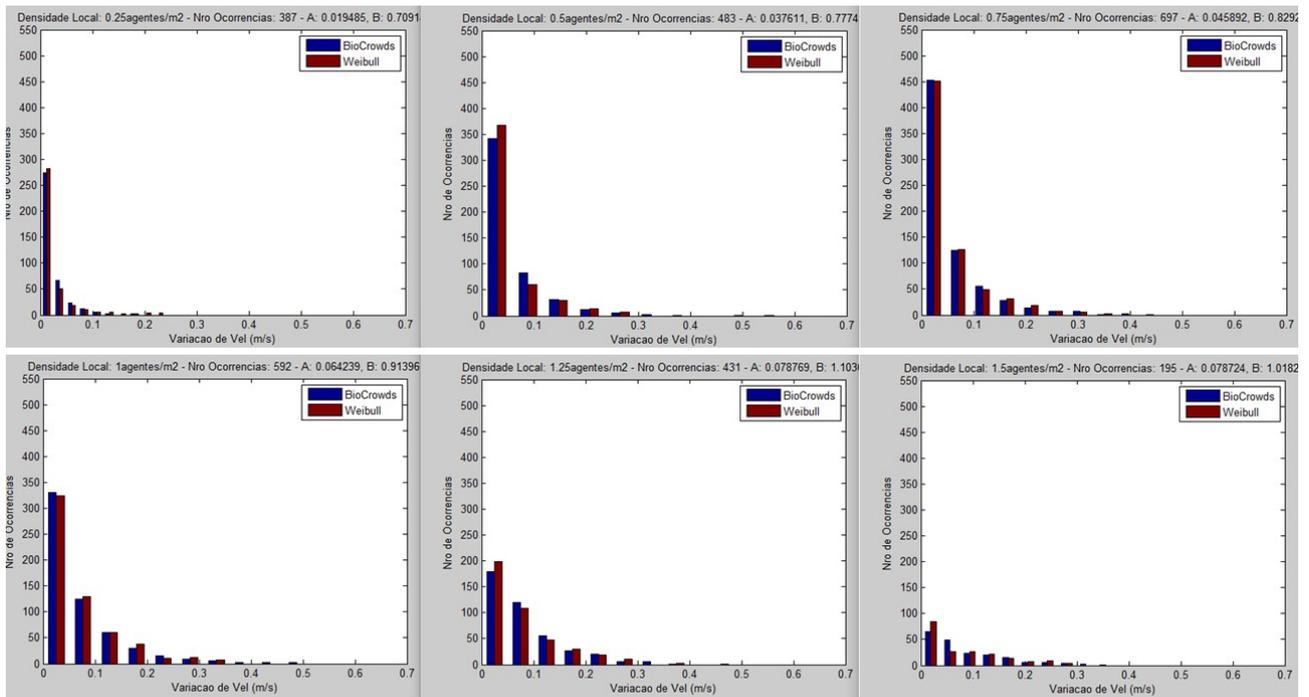


Figura 4.2 – Histogramas de redução de velocidade nos pares de  $d$  simulações do BioCrowds e redução de velocidades geradas aleatoriamente de acordo com a distribuição Weibull (em m/s)

As posições geradas em  $\vec{tm}_{t+\Delta t}^i$  representam as posições computadas para os agentes no tempo futuro  $t+\Delta t$ . No entanto, esse método não verifica se as posições geradas são válidas. Esse procedimento é explicado na próxima seção.

#### 4.1.4 Reposicionamento dos agentes

Este modelo descarta a necessidade de simulação e provê uma maneira analítica para geração de futuras posições, em simulações de multidão. Isso permite otimizar tempo de processamento quando comparado à realização de simulações contínuas. No entanto, as posições geradas analiticamente não são garantidamente coerentes e válidas. Por exemplo, a posição  $\vec{tm}_{t+\Delta t}^i$  (gerada com a Equação 4.7), para o agente  $i$  no tempo futuro  $t + \Delta t$  pode ser colocada no interior de um obstáculo ou sobreposta a outro agente. Para tratar esse problema, foi implementada uma extensão do BioCrowd original.

Essa extensão lê o vetor de posições  $\vec{tm}$  dos agentes e as considera como posições desejadas, e não finais. O BioCrowds tenta posicionar cada agente em sua posição desejada, mas se não for possível, busca a posição livre mais próxima possível. Devido à estrutura do modelo competir por marcadores, conforme apresentado no Capítulo 2, os agentes são colocados exatamente na posição  $\vec{tm}$ , quando esta posição possuir marca-

dores livres. Caso contrário, o algoritmo busca por marcadores livres nas quatro direções cardeais (N, S, L, O), orientado pelo vetor objetivo e por um raio de percepção  $R_i$  do agente  $i$ , como apresentado na seção 2.3. A escolha da direção segue a seguinte estratégia:

- as primeiras direções a serem buscadas são perpendiculares ao vetor objetivo, uma vez que se mover nesta direção pode impactar menos o tempo para alcançar o objetivo. Caso não haja marcadores disponíveis nessa direção, as demais direções são consideradas;
- se nenhuma das quatro direções possuir marcadores livres, consideram-se as demais quatro direções diagonais (NO, NE, SO, SE) da mesma forma.
- se nenhuma das direções avaliadas apresentar marcadores livres, o algoritmo aumenta o  $R_i$  em 0.45 (diâmetro de um agente), e a estratégia  $i$  é retomada.

O processo é repetido até que o algoritmo localize espaço para posicionar o agente. Esse processo acarreta erros (avaliados na próxima seção), que são, em geral, aceitáveis, uma vez que o modelo possibilita o processamento instantâneo da *Time Machine*, sem a necessidade de simular qualquer trajetória durante o avanço dos *frames* entre  $t$  e  $t + \Delta t$ .

As simulações com agentes fornecem uma ampla possibilidade de reproduzir situações de abandono de local e que ocasionam comportamentos emergentes através de cenários complexos, como, por exemplo, cenários com altas densidades e presença de obstáculos. Essas situações foram investigadas nos trabalhos de Berseth e colegas [6] e de Haworth e equipe [30] em que os autores observaram o efeito dos obstáculos, tal como o local ideal para colocar pilares em cenários de evacuação com apenas uma saída. Com base nesses estudos e buscando simular situações dinâmicas durante o avanço de tempo adicionou-se no modelo proposto um procedimento para estimar o comportamento futuro da multidão quando ocorrem eventos, que será apresentado na seção a seguir.

## 4.2 Inclusão e Tratamento de Eventos

O procedimento para tratar de situações dinâmicas durante a simulação ou durante o avanço de tempo foi integrado ao modelo *Time Machine*, que por sua vez, foi incorporado ao simulador BioCrowds. É importante salientar que a integração com BioCrowds não é um requisito, uma vez que o modelo *TM* pode ser integrado a outros simuladores, pois ao pausar a simulação as informações são lidas, e, após o processamento, são devolvidas ao simulador. A seguir será descrito como foi incluso o tratamento de eventos no presente modelo. Primeiramente os eventos que serão tratados foram classificados em dois tipos:

- Eventos de alteração do ambiente: os quais podem modificar o ambiente, adicionando, mudando ou removendo obstáculos e saídas.

- Eventos de alteração de população: os quais incrementam ou decrementam o número de agentes, em qualquer instante da simulação.

Posteriormente, definiu-se um evento  $k$  como uma quintupla dada como  $e_k = \{t_k, \Delta t_k, \tau_k, \vec{O}_k, \vec{A}_k\}$ , onde  $t_k$  é o instante de início do evento;  $\Delta t_k$  é o tempo de duração do evento;  $\tau_k$  define o tipo do evento (para obstáculo, neste caso o  $\tau_k = 1$ , para população,  $\tau_k = 2$  e para ambos  $\tau_k = 3$ );  $\vec{O}_k$  é definido como  $\{o_k, \vec{d}_k\}$ , onde  $o_k$  é o número de obstáculos e  $\vec{d}_k$  a geometria dos obstáculos (lista de vértices que compõem esse obstáculo); e finalmente  $\vec{A}_k$  é definido como  $\{a_k, \vec{p}_k, \vec{g}_k, \vec{v}_k\}$ , onde  $a_k$  é o número de agentes,  $\vec{p}_k$ ,  $\vec{g}_k$  e  $\vec{v}_k$  são, respectivamente os arrays contendo as posições, os destinos e as velocidades para os agentes.

Após apresentar os principais tipos de eventos, será detalhada o processo de inclusão desses eventos no modelo. Primeiramente, estipulou-se que só serão tratados como eventos os acontecimentos que ocorrem durante o "avanço de tempo" no método *TM*. Os avanços de tempo nos quais ocorrem eventos são chamados de *Time Machine* com Evento (TM-E). Também definiu-se que os eventos que ocorrem após o término do avanço de tempo serão considerados na simulação.

O método permite a inclusão de mais de um evento no decorrer do avanço do tempo. Inicialmente, será apresentada a inclusão de um único evento  $e_k$ , iniciando no *frame*  $t_k$ . A estimativa inicial para cada agente  $i$  será computada usando a Física, similar a Equação (4.1), conforme segue:

$$\vec{X}'_{t_k} = \vec{X}_t + \left( s^i \frac{\vec{g}^i}{\|\vec{g}^i\|} \right) (t_k - t), \quad (4.9)$$

onde  $\vec{X}'_{t_k}$  é a posição do agente  $i$  no tempo da estimativa  $t_k$  quando  $e_k$  inicia, baseado somente pela Física.  $\vec{X}_t$  é a posição do agente  $i$  no *frame*  $t$  (último *frame* antes de iniciar o avanço de tempo),  $\vec{g}^i$  é o destino do agente e  $s^i$  é a velocidade desejada. Adicionalmente,  $t_k - t$  representa a diferença de tempo entre  $t$  e  $t_k$ .

Após a estimativa prévia da posição  $\vec{X}'_{t_k}$ , aplicam-se penalidades de acordo com o tipo de evento. Eventos  $e_k$  com  $\tau_k = 1$  (do tipo obstáculo) causam impactos na complexidade do ambiente ( $EC_{t_k}$ ), conforme obstáculos presentes no *frame*  $t_k$  (Equação (4.3)). Para eventos  $e_k$  com  $\tau_k = 2$  (do tipo população), também calcula-se um fator de redução devido ao impacto ocasionado pelas interações entre as pessoas ( $IP_{t_k}$ ), considerando a população no *frame*  $t_k$ . Para tanto, geram-se os valores de  $IP_{t_k}^i$  de acordo com a densidade local  $\rho^i$  que impacta o agente  $i$  no *frame*  $t_k$ , conforme Equação 4.7.

Desta forma, o ajuste da posição do agente  $\vec{X}''_{t_k}$  no *frame*  $t_k$  (onde o evento inicia) é dado por:

$$\vec{X}''_{t_k} = \vec{X}'_{t_k} - \left( s^i \frac{\vec{g}^i}{\|\vec{g}^i\|} \right) \cdot EC_{t_k} \cdot IP_{t_k}^i, \quad (4.10)$$

onde  $\vec{X}_{t_k}^i$  é a posição do agente  $i$  baseada na Física, no tempo  $t_k$ ,  $s^i$  é a velocidade do agente e  $\vec{g}^i$  é o seu destino.

Até este momento, descreveu-se a ocorrência de apenas um evento acontecendo entre os frames  $t$  e  $t + \Delta t$ , exatamente no momento do avanço de tempo. No entanto, é importante destacar que mais de um evento pode acontecer durante o avanço de tempo (Time Machine com Evento -TME). Neste caso, os valores de  $EC$  e  $IP$  também devem ser alterados durante o TM-E, considerando o evento ocorrido. A Figura 4.3 apresenta o fluxo de dados do TM-E, em função do tempo. A Figura 4.3 (a) demonstra o avanço de tempo (TM), onde os atributos do frame  $t$  são utilizados para calcular a posição prior no frame  $t + \Delta t$ , bem como o impacto das duas funções de penalidade  $EC_{t+\Delta t}$  e  $IP_{t+\Delta t}$  para estimar as posições do agente no frame  $t + \Delta t$ . Neste exemplo, não ocorreram eventos durante o tempo que as posições foram estimadas.

A Figura 4.3 (b) ilustra uma simulação onde dois eventos acontecem durante o avanço de tempo (eventos do tipo 1 e 2) nos frames  $t_1$  e  $t_2$ , respectivamente. Considerou-se que  $\tau_1 = 1$  ou seja  $e_1$  é do tipo obstáculo e  $\tau_2 = 2$  indica que  $e_2$  é do tipo população. No caso da Figura 4.3 (b), apresenta o aparecimento de nova população em  $t_1$  e de obstáculos no frame  $t_2$ . O fluxo de execução é descrito a seguir. Primeiramente recalcula-se  $IP_{t_1}^i$  para cada agente  $i$ , considerando os dados dos agentes no frame  $t$  e da nova população em  $t_1$ . Além disso, a Equação 4.10 é computada para a posição de cada agente no frame  $t_1$ . Posteriormente,  $EC_{t_2}$  é calculado baseado nas informações do frame  $t_2$ . Além disso, como o evento iniciado no tempo  $t_1$  segue ocorrendo, é necessário tratar-se eventos de população também, ou seja incluir  $IP_{t_2}^i$  e novamente recalcular a Equação 4.10, computando a posição de cada agente no frame  $t_2$ . Deste

Por fim, se os dois eventos seguem ocorrendo em  $t + \Delta t$ , a Equação 4.10 é novamente calculada neste tempo levando em consideração  $IP_{t+\Delta t}^i$  e  $EC_{t+\Delta t}$ .

A partir da inclusão de eventos, percebeu-se a necessidade de comparar as multidões estimadas e simuladas, não somente através do erro por agente, com a métrica da Equação (4.2) que compara individualmente as posições, mas de uma maneira mais abrangente, pela densidade das populações. Para tanto, foi proposta uma segunda métrica, para comparar o resultado da simulação contínua e da simulação com TM-E, baseada nas informações de densidade local e com intuito de fornecer uma diferença estimada das multidões. Assim, dividiu-se o ambiente de simulação em regiões uniformes chamadas de *células* ( $c$ ). Neste caso, essa métrica de comparação global é a diferença média relativa em população das células que discretizam a área do ambiente, por frame  $t$ , dada por:

$$Dif_t = \frac{\sum_{c=1}^{N_{cell}} |sc_t - ec_t|}{Avg(sc_t)}, \quad (4.11)$$

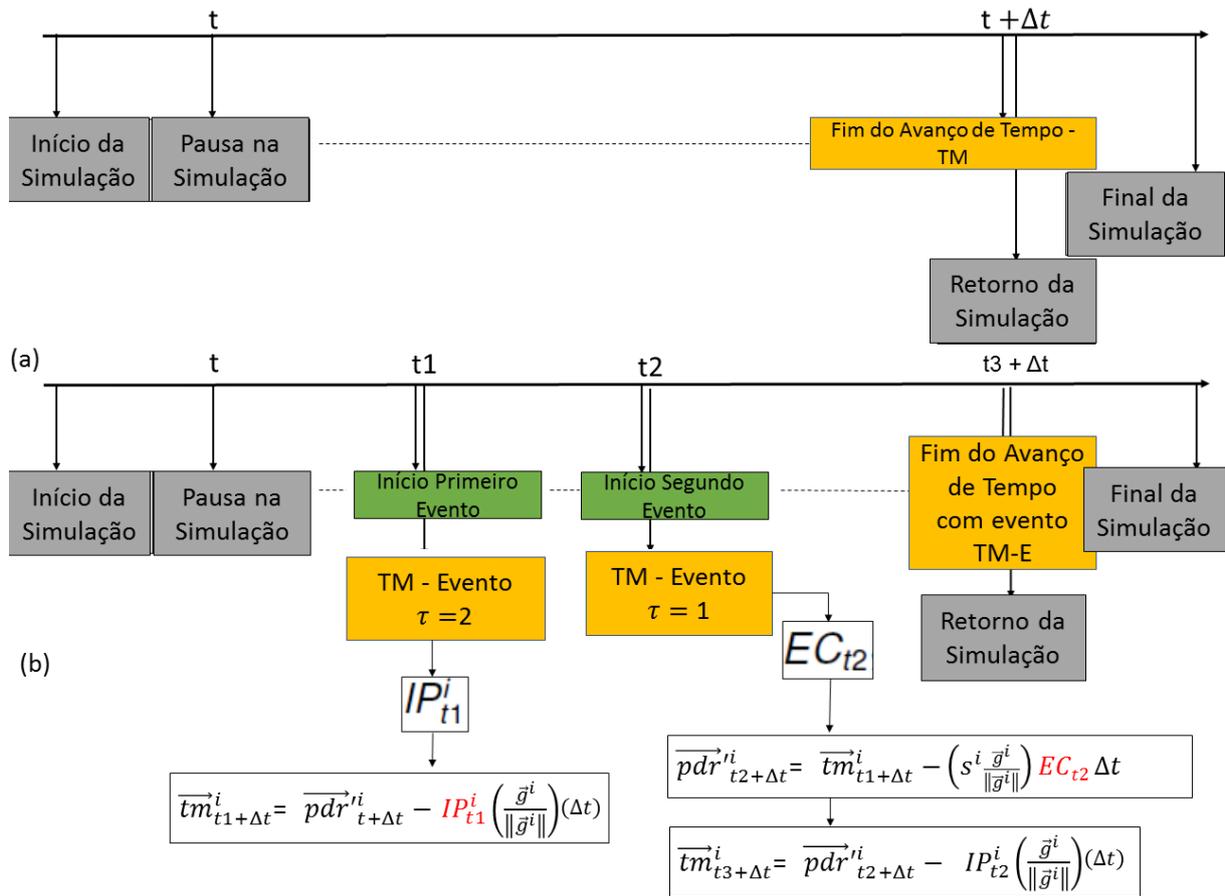


Figura 4.3 – Fluxo de dados durante a simulação. (a) Avanço de tempo sem evento (TM). (b) Dinâmica do avanço de tempo com eventos (TM-E) considerando eventos  $\tau_2 = 1$  e  $\tau_2 = 2$

onde,  $sc_t$  e  $ec_t$  referem-se à quantidade de agentes em cada célula específica  $sc$  da simulação contínua e do método TM ( $ec$ ) no frame  $t$ .  $N_{cell}$  refere-se ao número de células das simulações e  $Avg(\cdot, \cdot)$  é a média de pessoas por célula, considerando as células ocupadas.  $Dif_t$  é um valor adimensional.

### 4.3 Integração com o BioCrowds

O modelo previamente descrito foi integrado ao simulador BioCrowds. Assim como usual em outros simuladores, o BioCrowds necessita receber informações do ambiente e da multidão para processar os cálculos que envolvem a simulação. Originalmente o BioCrowds necessita de informações sobre a multidão e sobre o ambiente, a constar:

- informações relativas à multidão: quantidade de grupos e número de pessoas por grupos, posições de origem e posições de destino (em coordenadas de mundo) individuais ou por grupo, adicionalmente é possível configurar o espaço pessoal dos agentes (*proxemics*).

- dados relativos ao ambiente: dimensão do cenário virtual, dimensão e posição dos obstáculos, além de outros parâmetros, não obrigatórios, mas que podem ser alterados, tais como o fator que determina a distância mínima entre marcadores e a taxa de *frames* por segundo para visualização.

Outros parâmetros precisam ser fornecidos antes de iniciar a execução da simulação, sendo possível executar a simulação contínua ou com *Time Machine*.

1. Na simulação contínua as informações de entrada serão processadas *frame à frame*, sem interrupção, e executam-se os cálculos para o deslocamento da multidão, conforme seção do BioCrowds (Capítulo 2).
2. Para a simulação com *Time Machine* é necessário informar o instante de tempo no qual se deseja iniciar a estimativa e o instante da finalização da estimativa. Ao final do processamento das estimativas, e de posse das posições estimadas, a simulação poderá ser retomada e processada até todos os agentes alcançarem seus objetivos ou finalizada. Para a *Time Machine* com eventos (TM-E), os seguintes parâmetros devem ser informados: (i) tempo de início e finalização do evento. (ii) o tipo de evento, lembrando que os eventos podem ser  $\tau = 1$  para obstáculos,  $\tau = 2$  para população,  $\tau = 3$  ambos. Para os eventos  $\tau = 1$ , deverão ser fornecidas as dimensão dos obstáculos e as respectivas posições. Para eventos  $\tau = 2$ , deverão ser informadas as posições de origem e destino dos indivíduos e o tamanho da população. Para eventos  $\tau = 3$  também serão necessários especificar os dados dos obstáculos e da população.

Ao final da simulação, é possível exportar os dados produzidos em cada passo de simulação através de um arquivo XML, contendo especificações das trajetórias realizadas por cada agente em cada *frame*. Imagens também podem ser capturadas a cada passo da simulação.

## 5. RESULTADOS

Esse capítulo apresenta os resultados obtidos com o modelo proposto nesta tese, o qual visa prover o comportamento futuro da multidão tendo como base as estimativas obtidas pela técnica *PDR*, integrada com a análise da complexidade do ambiente, além de propor uma medida para o quanto as pessoas interferem nas outras em multidões. Neste caso, as posições de todos os agentes da simulação são estimadas em um tempo futuro. Durante os testes realizados na fase de implementação do modelo, o mesmo revelou-se adequado para tal objetivo. Porém, durante a fase experimental levantou-se a seguinte questão: e se alguns agentes forem simulados, durante o intervalo de tempo no qual se deseja realizar a predição, e a partir das informações destes agentes determinar a futura posição do restante da multidão, seria possível obter resultados melhores do que os obtidos até o momento com a *Time Machine*?

Essa hipótese foi implementada e avaliada através de experimentos. Tais experimentos também foram testados no Modelo da *Time Machine* com estimativas, permitindo assim, realizar comparações de resultados e gerar insumos para avaliar o modelo proposto neste trabalho. Detalhes da implementação dessa hipótese e experimentos serão apresentados na Seção 5.1. Posteriormente serão demonstrados os experimentos com a *Time Machine* (Seção 5.2) e os testes empregados para validar o modelo da *Time Machine* com a inclusão de eventos (Seção 5.3). Por fim será relatado o desempenho da *TM* com eventos em situações reais (Seção 5.4).

### 5.1 Método: *Time Machine* com Líder

Esse método visa prever o futuro da multidão a partir da simulação de alguns agentes no intervalo de tempo  $t$  (instante que deseja-se iniciar a predição) até  $t + \Delta t$  (instante para a finalização da predição). Os agentes simulados nesse intervalo de tempo ( $t$  até  $t + \Delta t$ ) foram chamados de líderes e os demais foram nomeados de seguidores. Dada uma simulação computacional de multidão, a execução deste método inicia-se no tempo  $t$  capturando os seguintes dados dos agentes: posição que é dada por  $\vec{X}_t = (x_t, y_t, z_t)$ , velocidade ( $s$ ), destino ( $\vec{g} = g_x, g_y, g_z$ ), números de grupos da multidão ( $G$ ) e número de agentes em cada grupo ( $G_a$ ). De posse dessas informações selecionam-se 10% dos agentes por grupo para servirem de líderes. Para selecionar os líderes de cada grupo utilizou-se critérios baseados na distribuição da multidão no espaço cartesiano, tentando cobrir o espaço

da melhor maneira possível. Assim, o primeiro líder é o agente que apresenta o maior valor de  $y$ , o segundo líder é o agente que possui o menor valor de  $y$ , o terceiro e o quarto líderes são os agentes com maior e menor  $x$ , para grupos com população superior à 39 agentes. Após a seleção dos líderes executaram-se as seguintes operações:

1. Identificar os seguidores de cada líder. A ideia é que cada líder influencie os agentes que estão na sua zona de vizinhança espacial. Por isso, para determinado líder  $j$ , encontram-se os agentes mais próximos à ele, do que de qualquer outro líder. Para tanto, utilizou-se a distância Euclidiana. Por exemplo, um grupo com 20 agentes (destes agentes, dois são líderes), alocam-se os oito agentes mais próximos ao primeiro líder e o restante dos agentes são vinculados ao segundo líder, constituindo dois subgrupos com os líderes e respectivos seguidores. Assim, ao final desta etapa, tem-se calculados e armazenados os valores de distância entre cada líder e seus seguidores, no frame  $t$ , conforme Equações 5.1 e 5.2, onde  $\vec{l}id^j$  é a posição do líder  $j$  e a posição de determinado seguidor  $i$  é dada por  $\vec{s}eg^i$ :

$$\vec{shift}_{x,t}^i = \vec{l}id_{x,t}^j - \vec{s}eg_{x,t}^i, \quad (5.1)$$

$$\vec{shift}_{y,t}^i = \vec{l}id_{y,t}^j - \vec{s}eg_{y,t}^i. \quad (5.2)$$

2. Simular os líderes no intervalo de  $t$  até  $t + \Delta t$ . Calcular e armazenar as posições  $\vec{l}id_{t+\Delta t}^j$ .
3. A partir da posição do líder  $\vec{l}id^j$  no instante  $t + \Delta t$ , calcular a posição dos seguidores, ou seja a posição de um seguidor será baseada na posição do respectivo líder com o ajuste do deslocamento previamente computado (de acordo com etapa 1), conforme as Equações 5.3 e 5.4:

$$\vec{s}eg_{x,t+\Delta t}^i = \vec{l}id_{x,t+\Delta t}^j - \vec{shift}_{x,t}^i, \quad (5.3)$$

$$\vec{s}eg_{y,t+\Delta t}^i = \vec{l}id_{y,t+\Delta t}^j - \vec{shift}_{y,t}^i. \quad (5.4)$$

Os testes realizados e resultados obtidos com essa metodologia serão apresentados nas próximas subseções.

### 5.1.1 Experimentos com Líder

Esses experimentos são apresentados a fim de avaliar o desempenho da implementação com líder, que foi planejada para realizar as predições em um intervalo de tempo ( $t$  até  $t + \Delta t$ ). Neste caso, durante um certo período de tempo, no máximo quatro líderes por grupo (dado que nenhum grupo tem mais de 40 agentes) foram simulados. Ao final deste intervalo, as posições dos demais agentes foram atualizadas usando como referência a posição do líder. As próximas subseções 5.1.1 e 5.1.2, apresentarão os cenários e as métricas empregadas para análise, bem como os resultados deste método.

#### Cenários

Para a avaliação da metodologia de predição com líder, foi utilizado um cenário com dimensão de  $920m^2$ , ( $23m \times 40m$ ) e com quatro diferentes configurações de obstáculos, a saber:

- 2 obstáculos com  $A_o = 109,71m$ ,
- 4 obstáculos com  $A_o = 582,22m$ ,
- 6 obstáculos com  $A_o = 128,68m$ , e
- sem obstáculo.

A Figura 5.1 ilustra esses cenários. Para todos os cenários foram analisadas quatro simulações, com população de 8, 80, 160 e 320 agentes. Neste caso, utilizou-se a densidade de marcadores de 0,175.

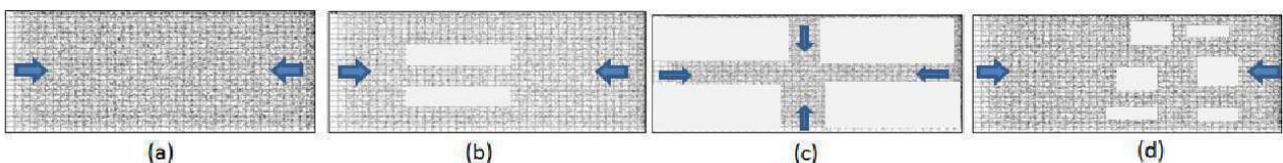


Figura 5.1 – Diferentes cenários usados para a avaliação. (a) sem obstáculos. (b) 2 obstáculos. (c) 4 obstáculos e (d) 6 obstáculos

### 5.1.2 Validação *Time Machine* com Líder

As diferenças entre a simulação Contínua e a *Time Machine* com líder foram analisadas a fim de validar a metodologia proposta. Simulação contínua refere-se à simulação

iniciada com toda a população e executada ininterruptamente até a finalização, enquanto a *Time Machine* com líder reporta-se à simulação inicializada da mesma forma que anterior, mas que, em determinado tempo  $t$ , foi pausada e deste instante até  $t + \Delta t$  simularam-se somente os líderes. Depois desse processamento, a simulação foi retomada com toda a população (líderes e seguidores) que foi reposicionada de acordo com as informações resultantes das Equações 5.3 e 5.4. Avaliaram-se os erros usando a métrica individual medindo a média do erro de cada agente  $i$ , de acordo com a Equação 5.5 (similar a Equação 4.2).

$$Dif_{t \rightarrow t+\Delta t}^i = \frac{d(\vec{X}_{t+\Delta t}^i, \vec{tm}_{t+\Delta t}^i)}{d(\vec{X}_t^i, \vec{X}_{t+\Delta t}^i)}, \quad (5.5)$$

onde  $\vec{X}_t^i$  é a posição do agente  $i$  no *frame*  $t$  (quando a simulação foi pausada).  $\vec{tm}_{t+\Delta t}^i$  e  $\vec{X}_{t+\Delta t}^i$  são posições do agente  $i$  no *frame*  $t + \Delta t$  empregando TM e a simulação (contínua, sem pausa), respectivamente. Além disso as diferenças também são analisadas empregando os dados de densidades conforme Equação 4.11.

As análises foram computadas em três instantes durante a execução da simulação *Time Machine* com líder. O primeiro *frame* analisado foi denominado  $t_1$  e refere-se ao instante da finalização da *Time Machine* e a volta da simulação ( $t + \Delta t$ ). Neste *frame*, o processo de reposicionamento (conforme detalhado na Seção 4.2) é executado, o que ocasiona alguns ajustes nas posições que estão ocupadas por obstáculos ou por outro agente. Em função desse exposto, observou-se que o *frame*  $t_1$  possui um erro maior, visto que é o exato momento da volta da TM e onde ocorrem ajustes. Assim, a hipótese é de que, após o reposicionamento, os erros tendem a diminuir. Para avaliar essa hipótese realizaram-se mais duas análises nos *frames* ( $t_2$  e  $t_3$ ) conforme detalhado na Tabela 5.1. Nesta tabela apresenta-se, na primeira coluna, o cenário analisado, a segunda coluna apresenta o número de agentes (população simulada), e as últimas três colunas demonstram os *frames* de análise.

A partir deste momento, serão apresentados os resultados quantitativos e qualitativos obtidos ao executar a *Time Machine* com Líder nos quatro cenários. As imagens (a) e (b) da Figura 5.2 demonstram os resultados das métricas relativas à densidade e à posição, respectivamente, obtidos no cenário sem obstáculo. A partir das avaliações das posições (a), observa-se que as diferenças foram inferiores a 0,31. Ao analisar-se a imagem referente a densidade (b), constata-se que a maior diferença foi de 0,38 (erro normalizado da distância) alcançada em  $t_1$  (1ª Análise) nos testes com a população de 320 agentes.

Ainda para o cenário sem obstáculos as imagens do centro da Figura 5.2 apresentam as capturas de telas da simulação contínua no *frame* de pause ( $t_1$ ) e nos dois instantes de análises ( $t_2$  e  $t_3$ ) com uma população de 80 agentes. As imagens da parte inferior da Figura 5.2 igualmente ilustram os resultados do método *Time Machine* com líder no *frame* de pause ( $t_1$ ) e nos dois outros instantes de análise ( $t_2$  e  $t_3$ ), com 80 agentes (8 líderes com 9 seguidores cada). Com base nos resultados, observa-se que: *i*) o erro tanto calculado

Tabela 5.1 – Relação de *frames* nos quais executaram-se as análises. O *frame* da volta está especificado na terceira coluna  $t_1$ , e os outros instantes das análises são apresentados nas colunas identificadas como  $t_2$  e  $t_3$

Cenários	População	$t_1$	$t_2$	$t_3$
Sem Obstáculos	8	400	500	600
	80	550	750	950
	160	650	850	950
	320	700	800	1100
Dois Obstáculos	8	400	500	600
	80	450	550	650
	160	500	600	800
	320	700	900	1100
Quatro Obstáculos	8	300	400	500
	80	370	470	670
	160	370	470	670
	320	570	670	770
Seis Obstáculos	8	400	500	600
	80	550	750	950
	160	550	750	950
	320	700	800	1100

por agente, como por densidade diminui conforme os frames avançam na simulação; *ii*) é possível perceber alguma similaridade visual entre a simulação com líder e a contínua.

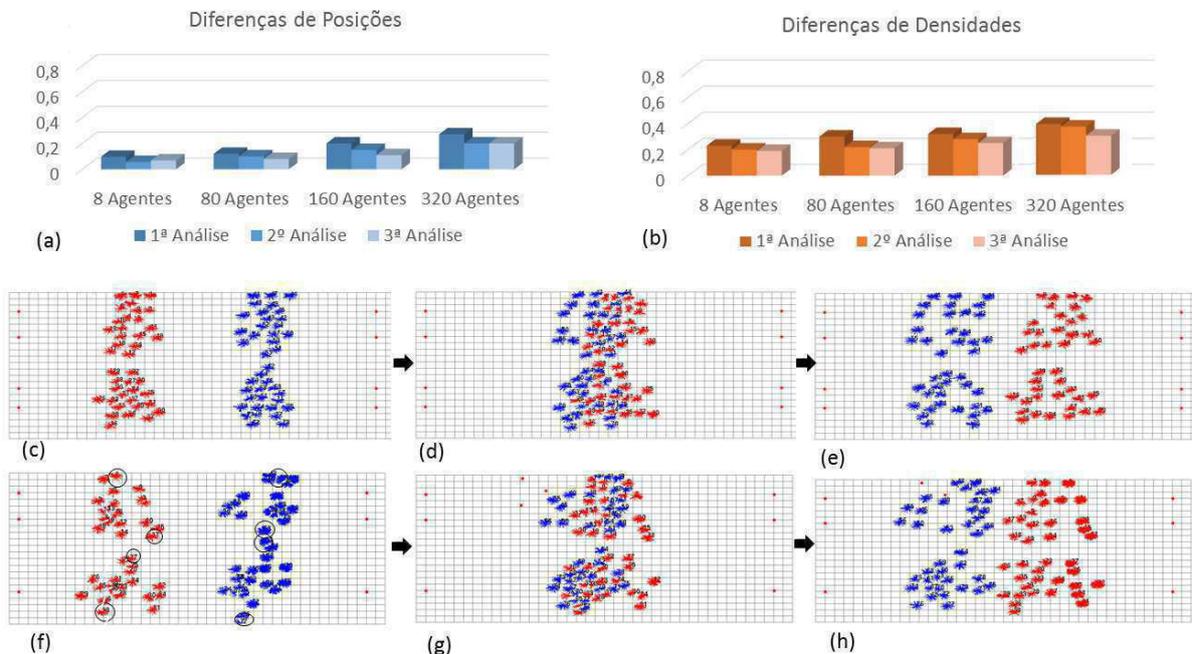


Figura 5.2 – Resultados para o cenário sem obstáculos. (a) Diferenças em relação às posições. (b) Diferenças em relação às densidades para todas as população nos três instante de análise. Imagens da simulação contínua (segunda linha) e da TM com líder (terceira linha) para uma população com 80 agentes no cenário sem obstáculo. (c) e (f) *frame* de pausa. (d) e (g) *frame* da volta ( $t_1$ ). (e) e (h) segundo instante de análise ( $t_2$ )

Para o cenário com dois obstáculos, as comparações entre a simulação contínua e a simulação TM com líder, considerando as diferenças de posições e as diferenças de densidades, são apresentadas nos gráficos (a) e (b) da Figura 5.3. Em todos os testes, é possível observar que no instante da volta (barras escuras) acontecem os maiores erros. Para a simulação com 320 agentes (a), o erro médio por agente, no *frame* da volta, chega a 0,5. Ressalta-se que o instante da volta,  $t_1$ , da simulação com TM ocorre justamente entre os dois obstáculos (conforme imagens (d) e (g)) aumentando a complexidade e recorrentes utilização do método de reposicionamento, o que impacta em erros. Quanto ao erro de densidade (b), observa-se erro máximo de 0,65 no  $t_1$  com 320 agentes.

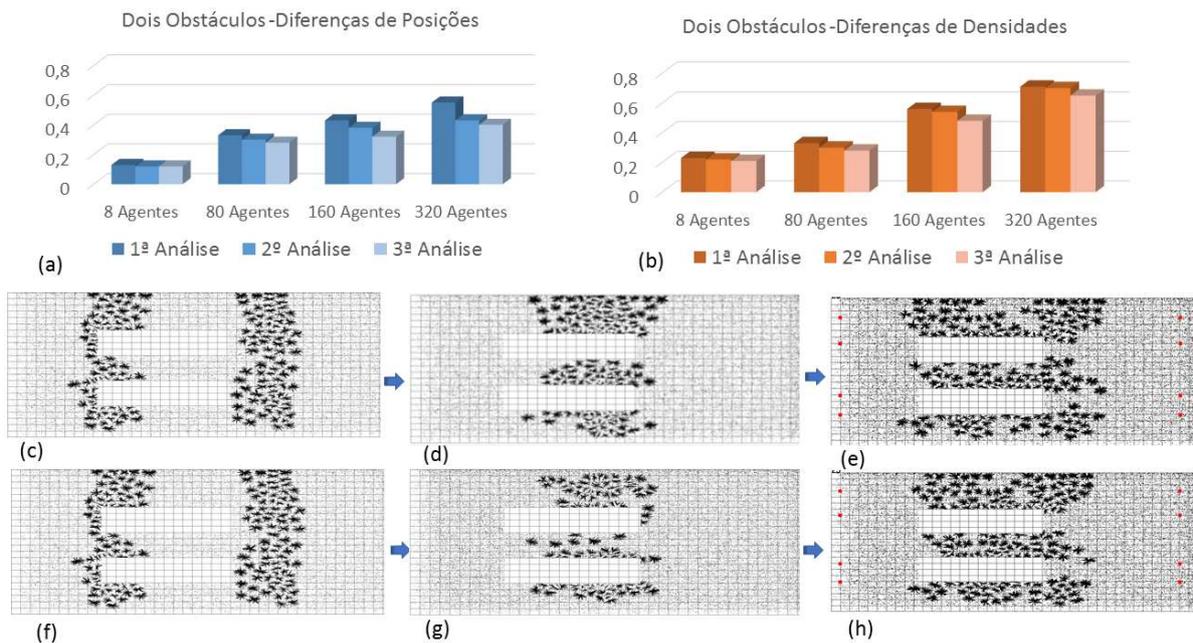


Figura 5.3 – Resultados do cenário com dois obstáculos. (a) Diferenças de Posições. (b) Diferenças de Densidades. As imagens do centro referem-se à simulação contínua e as imagens da parte inferior pertencem a TM com líder. (a) e (d) *frame* de pause -  $t$ . (b) e (e)  $t_1$  - *frame* da volta. (c) e (f) segundo instante de análise -  $t_2$

Outrossim, os gráficos (a) e (b) da Figura 5.4 mostram as diferenças relativas às posições e às densidades, respectivamente, para o cenário com quatro obstáculos (dois corredores que se cruzam). Os maiores erros são observados nas simulações com 320 agentes, chegando próximo a 0,8 nas investigações com as informações de posições e a 1,5 nas comparações com as densidades. Esses erros diminuem conforme o tempo passa, de acordo com as análises apresentadas em  $t_2$  e  $t_3$ . Neste cenário, por conta das dimensões dos obstáculos ocuparem 64% da área, foram observados os maiores erros quando comparado àqueles observados nos demais cenários. As duas últimas linhas da Figura 5.4 apresentam as capturas de tela no *frame* de pause ( $t$ ) e em dois instantes de análises ( $t + \Delta t$  e  $(t + \Delta t) + 200$ ) para a simulação contínua ((c), (d) e (e)) e para a *Time Machine* com líder ((f), (g) e (h)). Destaca-se que para essa situação, o avanço de tempo foi

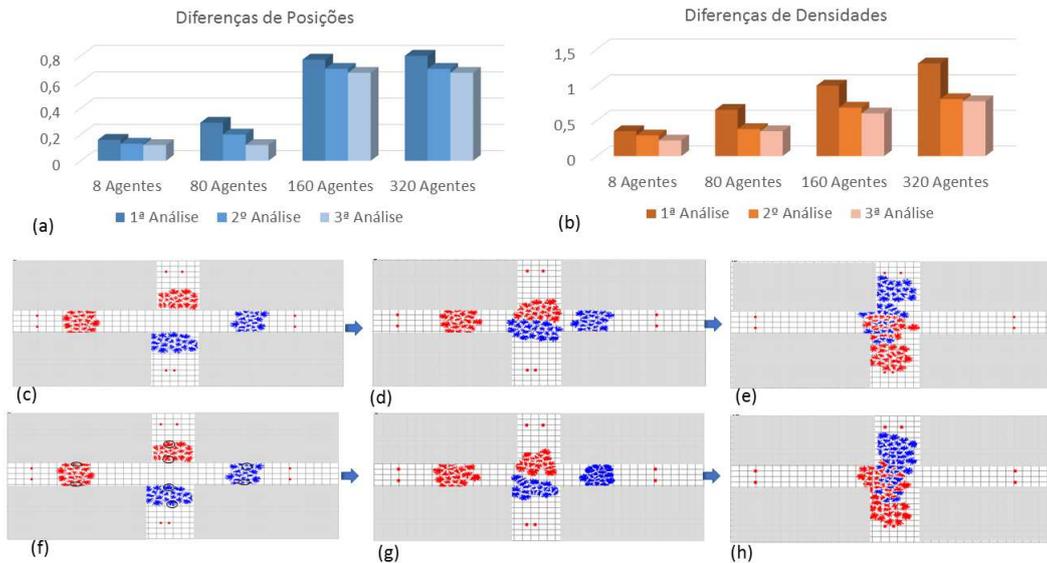


Figura 5.4 – (a) e (b) Resultado da métrica de posição e densidade, respectivamente, para todas as população nos três instante de análise no cenário com quatro obstáculos. Capturas de tela do cenário com seis obstáculos nas simulações com 80 agentes, as imagens da primeira linha referem-se a simulação contínua e as imagens (f) à (h) referem-se a simulação TM com líder. (a) e (d) *frame* de pause -  $t$ . (b) e (e) *frame* da volta -  $t_1$ . (c) e (f) segundo instante de análise -  $t_2$

de 4,17 segundos, ou seja 100 *frames* menor que os anteriores. Esse intervalo foi assim configurado para possibilitar que toda população estivesse presente no *frame* da volta.

A Figura 5.5 apresenta os resultados dessas métricas, para o cenário com seis obstáculos. O gráfico (a) apresenta as diferenças relativas à posição e o gráfico (b) as diferenças em relação à densidade. Percebe-se que as diferenças na 1ª Análise ( $t_1$ ) foram maiores para todas as populações, chegando a 0,20 nas simulações com 320 agentes, isso justifica-se pois foi o instante de finalização da estimativa e onde normalmente ocorrem reposicionamentos por conta da estimativa gerar posições que estão ocupadas por obstáculo ou agente. As capturas de tela da simulação contínua são apresentadas nas imagens (c), (d) e (e) da Figura 5.5, que correspondem ao *frame* de pause  $t$ , ao *frame* da volta ( $t_1$ ) e ao segundo instante de análise ( $t_2$ ), respectivamente, no cenário com seis obstáculos e população de 80 agentes. Os dois líderes de cada grupo estão circulados na imagem (f). E as imagens (f), (g) e (h) demonstram os mesmos instantes capturados na *Time Machine* com líder.

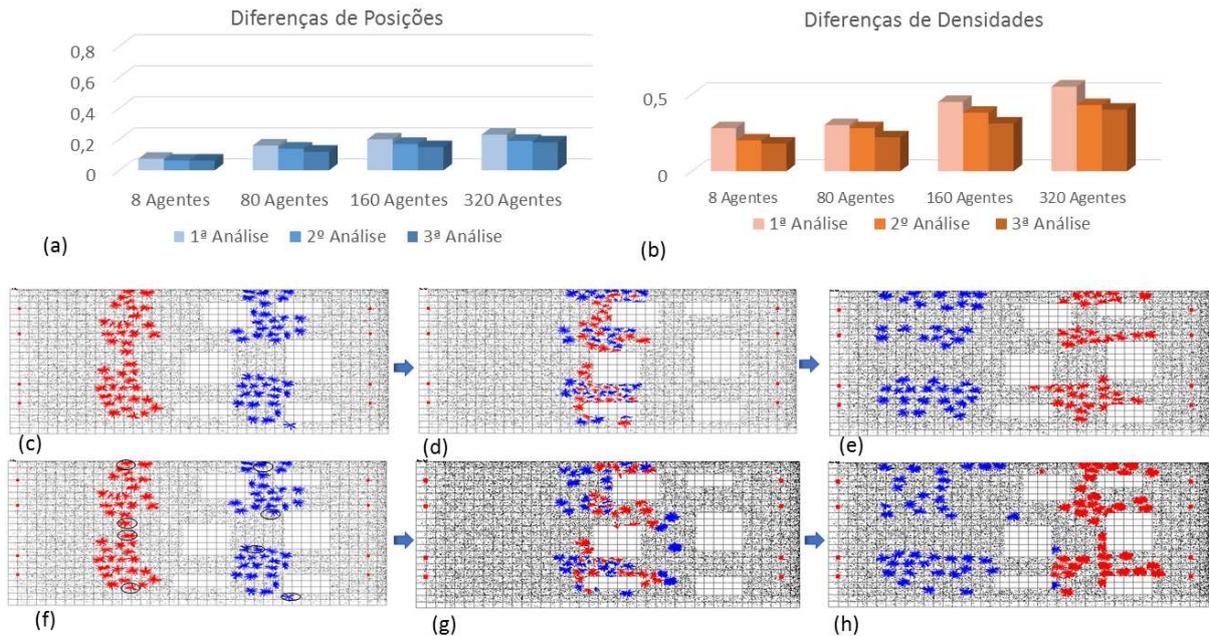


Figura 5.5 – Resultados para o cenário com seis obstáculos. (a) Diferenças de Posições. (b) Diferenças de Densidades. As imagens do centro referem-se a simulação contínua e as imagens da parte inferior pertencem a *TM* com líder. (c) e (f) *frame* de pause. (d) e (g)  $t_1$  *frame* da volta. (e) e (h) segundo instante de análise  $t_2$

### 5.1.3 Análise geral considerando os quatro cenários e a *TM* com líder

Ao realizar-se uma análise geral dos resultados obtidos nos quatro cenários de estudo (sem obstáculo, dois, quatro e seis obstáculos) com o modelo da *TM* com líder foi possível observar os seguintes aspectos:

- Os erros do *frame* da volta ( $t_1$  ou 1ª Análise), em todos os cenários, foram maiores tanto em relação ao erro de posições individuais quanto em relação as densidades globais;
- em relação às diferenças de posições de cada cenário, observa-se que no cenário sem obstáculo ocorreram os menores erros. Os maiores erros ocorreram no estudo de caso com quatro obstáculos, devido às dimensões dos obstáculos, que deixam apenas 36% da área total livre, ocasionando muitos reposicionamentos e, conseqüentemente, maiores erros. Comparando o erro neste dois cenários para as populações com 320 agentes o erro no cenário com sem obstáculo foi de 0,3 e com quatro obstáculo o erro chega à 0,8. Considerando as diferenças de densidade, prevalece a mesma constatação: as menores diferenças ocorrem no cenário sem obstáculos e as maiores no caso com quatro obstáculos.

Na próxima seção são apresentados os resultados provenientes do modelo para estimar comportamento futuro de multidão através da *Time Machine* com Estimativas (conforme detalhado no Capítulo 4). Essa metodologia, inicialmente, emprega o método *PDR* para determinar a estimativa prévia das posições dos agentes, segundo Equação 4.1, posteriormente atualiza essas posições com as informações do ambiente usando a Equação 4.3, e, por fim, ajusta as posições dos agentes, considerando as interações entre eles. Os detalhes sobre os resultados obtidos por meio das estimativas são apresentados na Seção 5.1.1. Os mesmos cenários apresentados na Seção 5.1.1 foram utilizados para avaliar esse modelo.

## 5.2 Experimentos com a *Time Machine* com Estimativas

Nesta etapa, são apresentados resultados a fim de avaliar a eficiência do modelo para predição de posicionamento de multidões em tempos futuros, por meio de estimativas, conforme detalhado no Capítulo 4. Para diferenciar da seção anterior (estimativa com líderes), nesta seção o modelo será chamado apenas de *Time Machine*. Da mesma forma que o experimento anterior, as simulações contínuas e com *Time Machine* foram executadas no Biocrowds. Simulações contínuas, neste caso, se referem às simulações sem parada ou avanço do tempo e as simulações com *Time Machine* dizem respeito àquelas com avanço de tempo em um determinado intervalo ( $t$  a  $t + \Delta t$ ). Para esse experimento são empregadas as mesmas configurações de cenários e parâmetros das populações do experimento com líder. Da mesma forma, as comparações (entre *TM* e contínua) ocorreram nos mesmos *frames*, ou seja nos tempos apresentados na Tabela 5.1.

### 5.2.1 Validações e Comparações

Para todos os cenários, foram avaliadas as diferenças relativas às posições. Para tanto compararam-se os resultados da *Time Machine* com a simulação contínua usando a Equação 5.5. A distância média (erro médio) de todos os agentes nos quatro cenários foram apresentadas na Figura 5.6.

Como pode ser visto na Figura 5.6, o erro médio de posicionamento de agentes aumenta, conforme aumenta o número de agentes simulados. Mas, mesmo para 8 agentes ocorreu um erro entre (0,05 e 0,1), dependendo do cenário utilizado. A média de todos os erros nos quatro cenários foi de 0,121. O maior erro foi 0,210 e ocorreu no cenário com quatro obstáculos, pois neste cenário a área livre para comportar todos os agentes é crítica, conforme ilustrado na Figura 5.1 (c). Também, para esse cenário, não foi possível realizar a simulação com 320 agentes em virtude do espaço limitado.

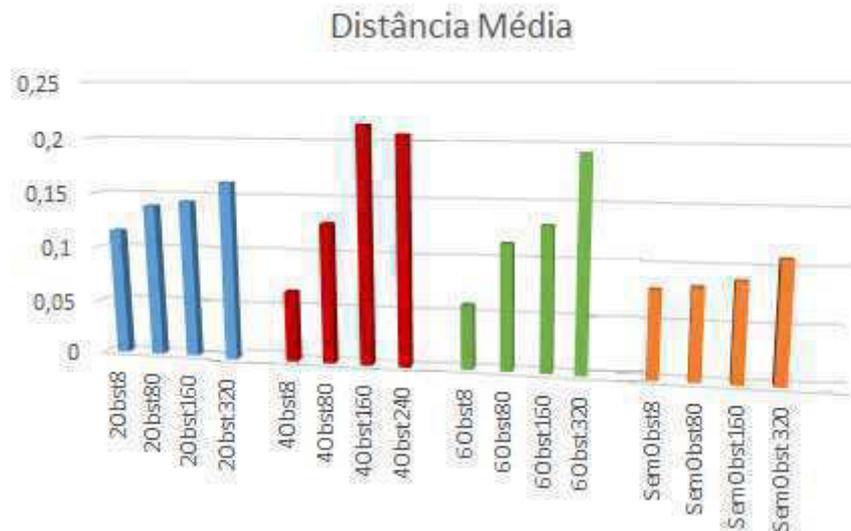


Figura 5.6 – Distância média quando comparadas as simulações com *Time Machine* com as simulações contínuas

Comparando-se os resultados desta seção com os resultados obtidos com a TM com Líder (apresentados na Seção 5.1.1), pode-se verificar que para as variações de população (8, 80, 160 e 320) e nos quatro cenários os erros alcançados pelo modelo *Time Machine* são inferiores aos gerados pela TM com Líder. Analisando, por exemplo, somente o instante de volta ( $t_1$ ) em todos os cenários, para a população de 320 agentes pode-se observar que: (i) para o cenário sem obstáculo o erro da TM com líder foi de 0,21 e da *Time Machine* foi de 0,12; (ii) para o caso com dois obstáculos, o modelo *Time Machine* apresentou uma redução de 0,34 em relação à TM com Líder e (iii) para o cenário com seis obstáculos, o erro diminuiu em 0,13 quando comparado ao erro obtido com a TM com Líder. Após todos esses experimentos, foi possível afirmar que o método com Líder não se mostrou promissor. Diante disso, todos os demais testes foram realizados somente com o modelo *Time Machine*.

A seguir será relatado um experimento variando a densidade de marcadores no ambiente. Posteriormente, serão apresentados os resultados do modelo *Time Machine* com eventos e, finalmente serão detalhados os testes realizados para comparar o modelo com cenários reais.

#### Avaliando a densidade de marcadores

Como a forma de movimentação dos agentes no simulador BioCrowds está intimamente relacionada ao número de marcadores presentes no ambiente, realizou-se uma segunda análise experimental com o intuito de verificar o quanto a densidade de marcadores impacta no erro obtido.

Alguns testes iniciais foram feitos para ajustar as distribuições de marcadores e encontrar a melhor relação entre o erro e o tempo de processamento (no BioCrowds são testados todos os marcadores do cenário para identificar o agente mais próximo, esse procedimento influencia o tempo de processamento, conforme discutido em [8]). Após os testes, chegou-se à distribuição de marcadores = 0,06 (a distância utilizada anteriormente foi de 0,175). A Figura 5.7 ilustra um cenário com as distâncias 0,175 e 0,06 entre os marcadores.

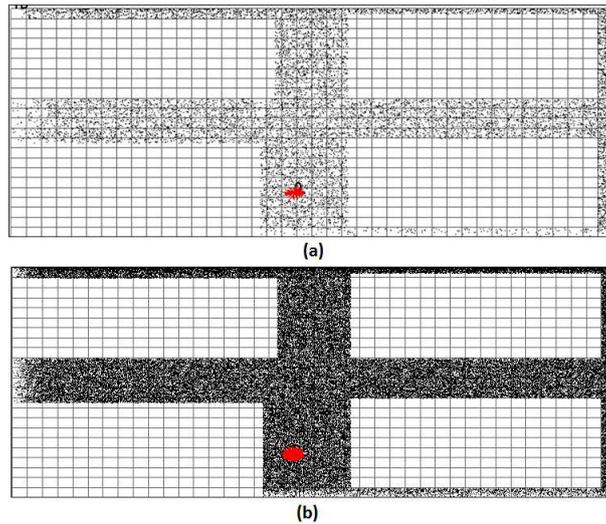


Figura 5.7 – Ilustração do cenário com diferentes distribuições de marcadores. (a) Distância padrão entre os marcadores igual a 0,175. (b) Distância reduzida entre marcadores igual a 0,06

Outras 64 simulações foram novamente executadas, e os erros médios de posicionamento de agentes foram calculados (empregando a Equação 5.5). Como feito anteriormente, consideraram-se o instante da volta da simulação ( $t_1$ ) e dois instantes adicionais de ( $t_2$  e  $t_3$ ), para investigar o erro da TM, conforme apresentado na Tabela 5.1.

Os cálculos das diferenças (erro entre simulação e *TM*), de acordo com a Equação 5.5, foram realizados para as duas distribuições de marcadores (0,175 e 0,06) nos mesmos instantes de análises, conforme descrito na Tabela 5.1. A Figura 5.8 apresenta os resultados das diversas combinações envolvendo os quatro cenários (Sem obstáculos, com dois, quatro e seis obstáculos), os diferentes números de agentes (8, 80, 160, 320), as duas densidades de marcadores (0,175 e 0,06) e três instantes de tempo ( $t_1$ ,  $t_2$ ,  $t_3$ ). As linhas da Figura 5.8 apresentam os gráficos de cada cenário. As colunas correspondem às quatro populações. Os eixos verticais dos gráficos correspondem aos instantes de tempo de análise. As barras azuis representam os resultados associados à menor densidade de marcadores (distância entre marcadores igual a 0,175 (Dist. Padrão) e número total de marcadores igual a 29.965). As barras laranja representam os resultados associados à

maior densidade de marcadores (distância entre marcadores igual a 0,06 (Dist. Reduzida) e número total de marcadores igual a 255.530)

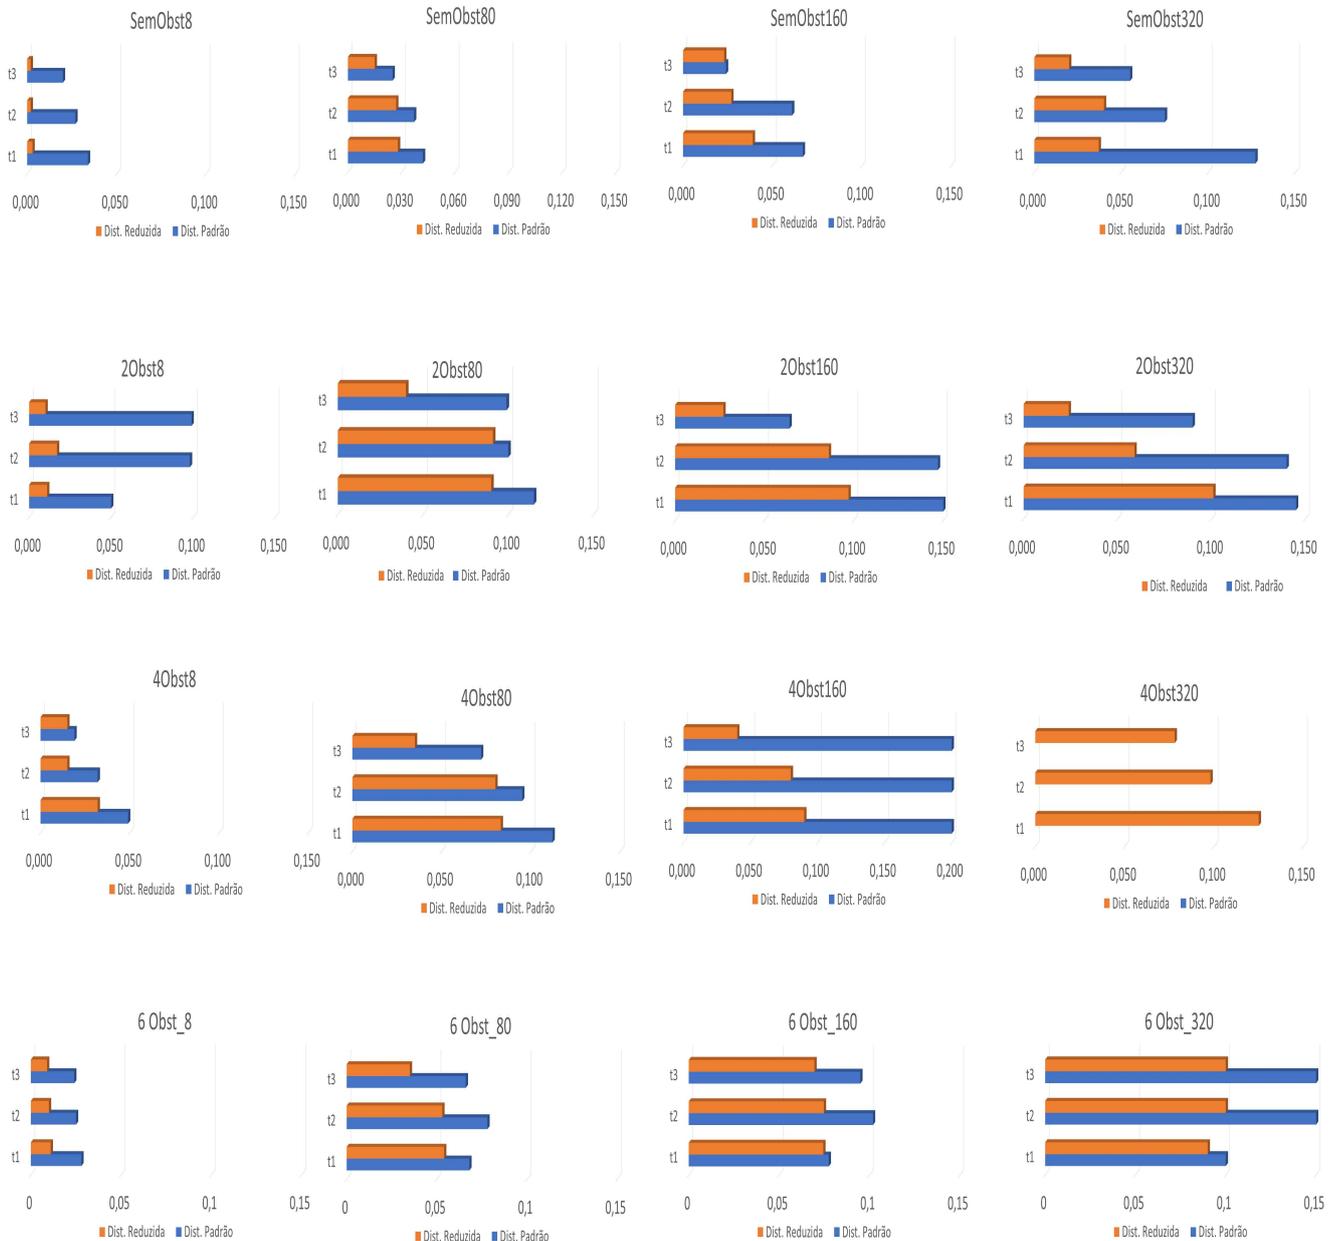


Figura 5.8 – Análise das diferenças de posições, nos quatro cenários, com duas distribuição de marcadores e em três instante de tempo das simulações ( $t_1$ ,  $t_2$  e  $t_3$ )

Percebe-se, que em todos os casos apresentados e para os três instante de análise,  $t_1$ ,  $t_2$  e  $t_3$ , os valores das distâncias dos cenários com maior número de marcadores (barras laranja na Figura 5.8) foram consideravelmente inferiores quando comparados às distâncias com menor número de marcadores (barras azuis). Constata-se ainda que o aumento de marcadores facilita o deslocamento de agentes, evitando possíveis trancamentos devido ao aumento da densidade local. Como pode ser observado na terceira linha da Fi-

gura 5.8 referente ao cenário com quatro obstáculos, a diferença das distâncias entre as duas distribuições foi significativa. Por exemplo, para a simulação com 160 agentes, e no instante ( $t_3$ ), os testes com distância reduzida entre os marcadores (barra laranja) apresentaram uma diminuição do valor do erro em aproximadamente 0,17. Ainda para o cenário com quatro obstáculos, ressalta-se que as simulações com 320 agentes só foi possível de ser executada com maior concentração de marcadores. Além disso, destaca-se que o maior erro encontrado foi 0,15, considerado simulações com distância reduzida entre os marcadores.

As diferenças em relação à densidade foram computadas (conforme Equação 4.11) para os quatro cenários, configurados com distância reduzida entre os marcadores. A Figura 5.9 apresenta as diferenças do instante da volta ( $t_1$ ). Sendo possível perceber que a menor diferença, para a população com 320 agentes, ocorreu no cenário sem obstáculos e a maior diferença aconteceu no cenário com quatro obstáculos, chegando à 0,4.

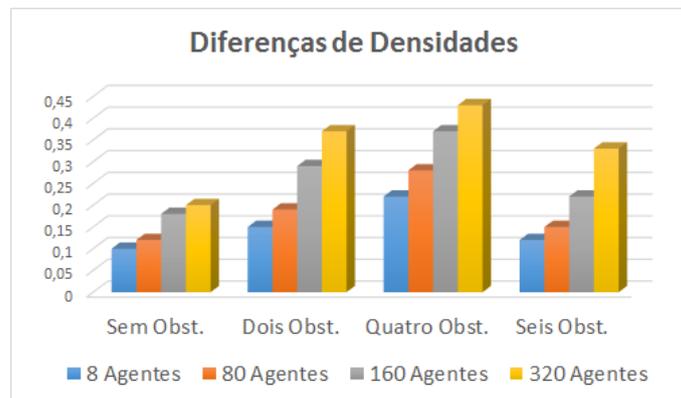


Figura 5.9 – Análise das diferenças de densidades no instante da volta ( $t_1$ ), nos quatro cenários, com distribuição de marcadores reduzida

### Avaliação Qualitativa

Com o intuito de apresentar alguns resultados qualitativos, capturou-se os instantes das simulações durante a execução do método TM e nos mesmos instantes durante a execução da simulação contínua. Foram mantidas as mesmas configurações iniciais (número de agentes, origens, objetivos, obstáculos) e com distribuições de marcadores de 0,06.

O primeiro cenário de análise discutido é apresentado na Figura 5.10. Esse cenário não apresenta obstáculos, e inclui 160 agentes em fluxo bidirecional. Nesta figura, são apresentadas imagens capturadas nos frames  $t = 350$ (a),  $t_1 = 650$  (b e d) e  $t_2 = 850$  (c e e) durante a simulação contínua (imagens no topo) e durante a *Time Machine*, (imagens abaixo). A imagem do instante  $t$  (momento de pause) é igual para ambas as simulações,

e apenas uma foi apresentada. Neste cenário foi fácil observar que a similaridade visual fica mais óbvia no segundo instante de análise (imagens à direita na Figura 5.10), ou seja, 8 segundos após o retorno da TM. Isto acontece pois, conforme dito previamente, algum tempo se passou e os agentes puderam se acomodar em suas posições geradas pela TM e continuam se dirigindo aos objetivos.

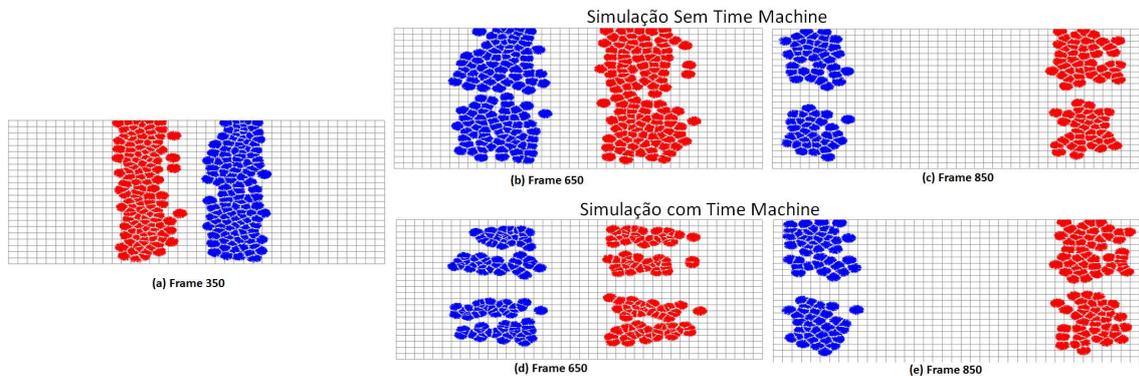


Figura 5.10 – (a) *Frame* de parada da simulação contínua e da *Time Machine*. (Topo) Simulação sem *Time Machine*: (b) primeiro instante de análise ( $t_1$ ), (c) segundo instante de análise ( $t_2$ ). (Abaixo) Simulação com *Time Machine*: (d) instante após o avanço ( $t_1$ ), (e) 8 segundos após o avanço ( $t_2$ ).

Um segundo cenário é apresentado na Figura 5.11, onde há dois obstáculos e 160 agentes em fluxo bidirecional. Foi possível observar a evolução da simulação durante os instantes:  $t = 200$  (a),  $t_1 = 500$  (b e d) e  $t_2 = 600$  (c e e) capturadas da simulação contínua (topo) e durante a *Time Machine* (abaixo). Da mesma forma, a imagem do instante  $t$  (antes do avanço no tempo) foi igual para ambas as simulações, optou-se por apresentar apenas uma. Sendo possível observar uma diferença visual entre a simulação com e sem *time machine* tanto no *frame 500* ( $t_1$ ) quanto no *frame 600* ( $t_2$ ).

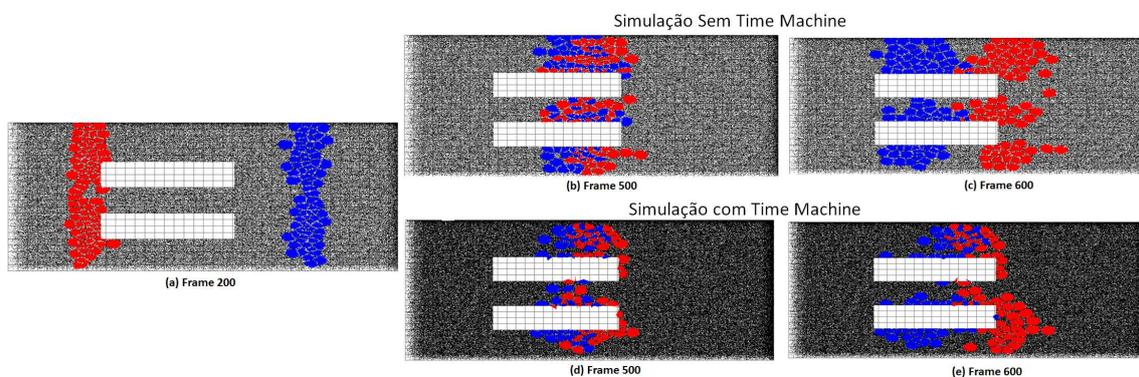


Figura 5.11 – (a) Instante de pausa da simulação contínua e da *time machine* ( $t$ ). (Topo) Simulação contínua: (b) primeiro instante de análise ( $t_1$ ), (c) segundo instante de análise ( $t_2$ ). (Abaixo) Simulação com *time machine*: (d) instante da finalização do avanço no tempo ( $t_1$ ), (e) 4 segundos após o avanço ( $t_2$ )

Assim como para os cenários anteriores, a Figura 5.12 ilustra o resultado das simulações com quatro obstáculos e 160 agentes com 4 fluxos de movimento. As imagens foram capturadas no *frame* de pausa(a)  $t = 200$ , e em dois instantes de análise  $t_1 = 370$  (b e d) e  $t_2 = 570$  (c e e) durante a simulação contínua (topo) e durante a *Time Machine* (abaixo). Nesta situação percebe-se que no instante da finalização da *Time Machine*( $t_1$ ), os resultados visuais podem ser considerados similares. Ainda, é possível verificar um resultado similar no segundo instante de análise ( $t_2$ ) ao inspecionar visualmente as simulações com e sem *Time Machine* (c e e). Ainda, no instante  $t_2$  é importante frisar que os grupos azul e verde já chegaram nos seus objetivos e, por isso, desapareceram da simulação.

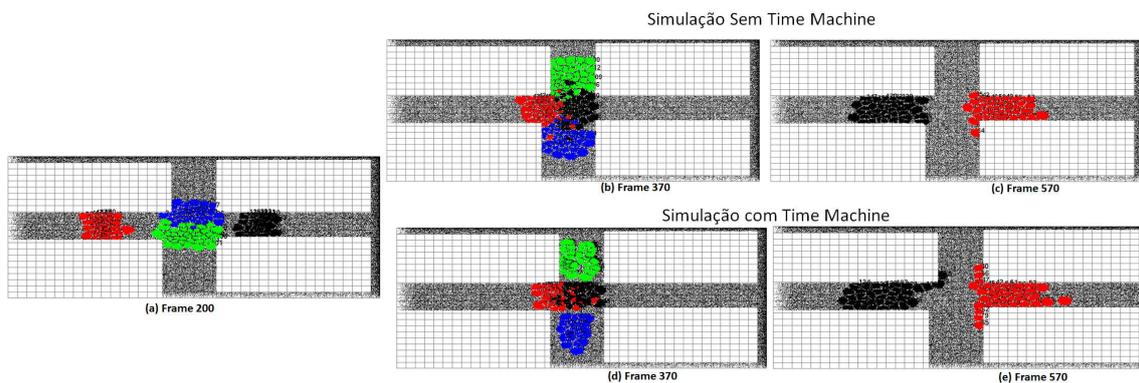


Figura 5.12 – a) *Frame* de parada da simulação contínua e da *Time Machine*. (Topo) Simulação sem *Time Machine*: (b) primeiro instante de análise ( $t_1$ ), (c) segundo instante de análise ( $t_2$ ). (Abaixo) Simulação com *Time Machine*: (d) instante após o avanço ( $t_1$ ), (e) 4,1 segundos após o avanço ( $t_2$ )

### 5.3 Experimentos com Cenários Dinâmicos

A fim de verificar os resultados gerados pelo modelo *Time Machine* com Estimativas, diante de situações dinâmicas, como a ocorrência de eventos (conforme Capítulo 4), executaram-se alguns experimentos, variando a população entre 8, 80, 160 e 320 agentes (cada um com diâmetro de 0,456m). Os três experimentos considerados são:

- A) Investigação do impacto do evento  $k$  do tipo  $\tau_k = 1$  (obstáculo) durante o avanço de tempo;
- B) Investigação do impacto do evento  $k$  do tipo  $\tau_k = 2$  (população) durante o avanço de tempo; e
- C) Investigação do impacto do evento  $k$  do tipo  $\tau_k = 3$  (obstáculos e população) durante o avanço de tempo.

### 5.3.1 Caso A: Investigação do impacto do evento $k$ tipo $\tau_k = 1$

Neste primeiro experimento, considerou-se um evento  $e_1$  do tipo  $\tau_{e_1} = 1$ , onde obstáculos são inseridos durante o avanço do tempo. O avanço de tempo com evento será referenciado como *Time Machine* com Evento (TM-E). Para essa investigação três comparações foram realizadas e computadas, em três instantes de tempo específicos, de acordo com as diferenças de posições individuais (conforme Equação 5.5) e de densidade (segundo Equação 4.11):

- i) Simulação contínua com e sem evento;
- ii) Simulação com TM-E com e sem evento; e
- iii) Simulação contínua e Simulação com TM-E com evento.

A Figura 5.13 apresenta dados de simulação e análise dos tempos em que ocorrem os eventos. A simulação com 8 agentes finaliza primeiro que as demais, e devido a isso, definiu-se um tempo menor para a permanência dos eventos. Para as demais a estratégia foi a mesma, o evento segue ocorrendo após a finalização do avanço de tempo. Ainda na Figura 5.13, é possível observar, para cada população simulada, os *frames* iniciais e finais do evento (linhas horizontais vermelhas) e os *frames* das comparações (setas verticais amarelas). A barra cinza escura indica o início e o fim da execução do método TM-E. Por exemplo, ao simular 8 agentes, o avanço de tempo iniciou no *frame* 100 e foi finalizado no *frame* 300, o evento  $e_1$  aconteceu do *frame* 150 ao *frame* 300 e os instantes das comparações foram nos *frames* 300, 500 e 600.



Figura 5.13 – Cada linha mostra a configuração para cada população. Linhas horizontais vermelhas definem o início e o fim de um evento, setas verticais amarelas indicam os *frames* de análise e as barras cinzas-escuras o tempo em que o método TM-E acontece

Para demonstrar o impacto de eventos do  $\tau_k = 1$  serão investigados dois cenários, o primeiro com a ocorrência de um obstáculo como evento, e o segundo com dois obstáculos. Os resultados obtidos são descritos a seguir.

#### *Um obstáculo*

De acordo com a definição de evento,  $e_1 = \{t_1, \Delta t_1, \tau_1, \vec{O}_1, \vec{A}_1\}$ , onde  $t_1$  e  $\Delta t_1$  definem o início e o fim do evento como ilustrado na Figura 5.13, dependendo do número de agentes. O parâmetro  $\tau_1 = 1$  especifica o evento como obstáculo, logo  $\vec{A}_1 = \emptyset$  e

$\vec{O}_1 = \{o_1, \vec{p}_1\}$ , onde  $o_1 = 1$  e  $p_1 =$  coordenadas dos objetos - neste caso é um quadrado com área de  $7 \times 7$ . A Figura 5.14 apresenta as diferenças médias de densidades das três investigações. No caso do gráfico (a) da Figura 5.14, apresentam-se as diferenças quando comparadas às mesmas simulações com e sem evento, nos 3 instantes de análises (conforme Figura 5.13). A Figura 5.14 (b) apresenta as diferenças relacionadas ao método TM-E com e sem evento, e por fim a comparação da simulação e do método TM-E com evento é apresentada na Figura 5.14 (c).

Observa-se que as diferenças obtidas no tempo 2 de análise (final do evento, exceto para 8 agentes), nas análises das simulações com e sem evento e TM-E com e sem evento, é maior quando comparada ao tempo 1 e ao tempo 3 (após o evento terminar). Isso ocorre porque só no tempo 2 o evento é finalizado, ou seja, se comparado ao tempo 1, neste instante o evento estava iniciando e no tempo 3 não estava mais ocorrendo, desta forma é no tempo 2 que percebe-se o maior impacto pois a diferença se propagou ao longo do tempo. Por outro lado nas análises da simulação e da TM-E com evento (c) a maior diferença foi percebida no tempo 1 (final do avanço de tempo). Isto ocorre pois é no tempo 1 que há os reposicionamentos dos agentes (devido à algumas posições estimadas estarem em áreas ocupadas por obstáculos ou pessoas) causando maior diferença. Outro ponto relevante, é que a diferença tende a diminuir à medida que o evento termina (o erro no tempo 3 é sempre menor do que no tempo 2 e às vezes também menor do que o erro no tempo 1).

Ressalta-se que a diferença máxima, observada quando comparamos a simulação e o método TM-E com evento (c), foi alcançada nos casos com 320 agentes, sendo de aproximadamente 0,3 alcançada no tempo 1. Nas análises feitas utilizando as informações das posições, para o experimento que comparou a simulação contínua e a TM-E com evento, e com uma população de 320 agentes obtiveram-se as seguintes diferenças, 0,21, 0,19 e 0,19 nos tempos de análises 1, 2 e 3, respectivamente. As diferenças de posições com as demais populações também foram computadas, mantiveram-se os padrões observados com as densidades(c) em que os primeiros instantes de análises foram os mais críticos, e a maior diferença foi alcançada com a população de 320 agentes. Desta forma, assume-se que o TM-E pode ser usado para estimar o movimento da multidão quando os eventos  $\tau_K = 1$  acontecerem, uma vez que a diferença entre TM-E e a simulação é pequena. Essas diferenças podem ser verificadas visualmente, na Figura 5.15, que apresenta as imagens das simulações, para os casos com 80 e 320 agentes.

### *Dois obstáculos*

Neste experimento alterou-se o número de obstáculos do evento tratado, com intuito de reafirmar os padrões observados no caso do estudo anterior. Desta forma, a formalização segue a mesma do caso anterior, com pequena alteração dos parâmetros

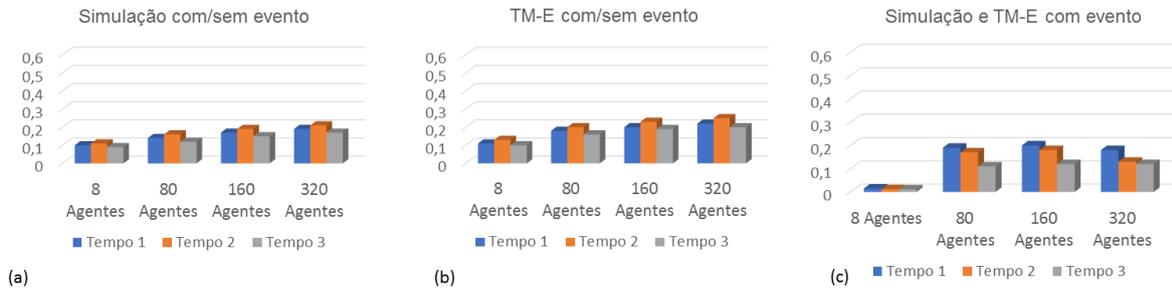


Figura 5.14 – Diferenças de densidades observadas nas três comparações relacionadas de um evento  $\tau_1 = 1$

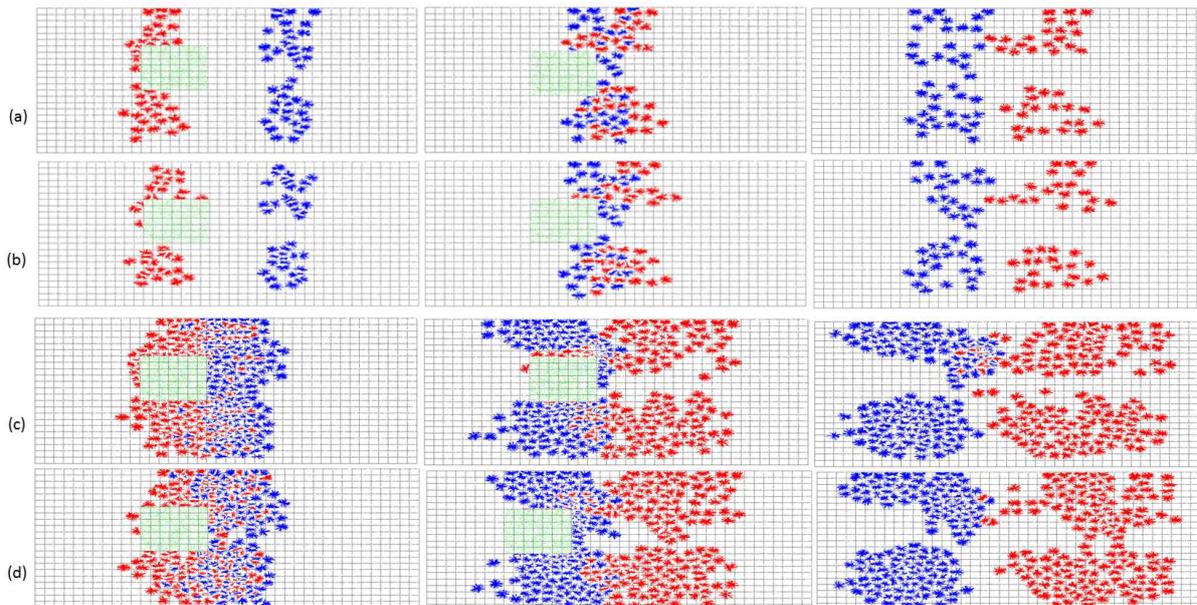


Figura 5.15 – Imagens das simulações (linhas a e c) e do método TM-E (linhas b e d) com 80 e 320 agentes, respectivamente, com evento  $\tau_1 = 1$  e  $\sigma_1 = 1$

conforme segue:  $\vec{O}_1 = \{o_1, \vec{p}_1\}$ , onde  $o_1 = 2$  e  $p_1 =$  coordenadas dos objetos que neste experimento serão dois retângulos de  $45m^2$ . Após realizar as simulações, verificou-se os resultados das métricas, na simulação com e sem eventos, no método TM-E com e sem eventos e nas simulação e no método TM-E com eventos. A Figura 5.16 apresenta os gráficos com as diferenças de densidades obtidas nestas 3 verificações, respectivamente nas Figuras 5.16(a), 5.16(b) e 5.16(c).

Observa-se na simulação com e sem evento(a) e no método TM-E com e sem evento (b), que os maiores erros foram observados no tempo 2 para todas as populações. A maior diferença foi de 0,50 obtida para a população com 320 agentes no segundo experimento. Pelo fato do terceiro experimento considerar eventos, tanto na simulação como no método TM-E, no tempo 2 (final do evento), as diferenças neste tempo são menores quando comparadas ao tempo 1 (*frame* da finalização do avanço de tempo) pois, neste exato momento, as posições são provenientes das estimativas e podem ocorrer reposicionamentos,

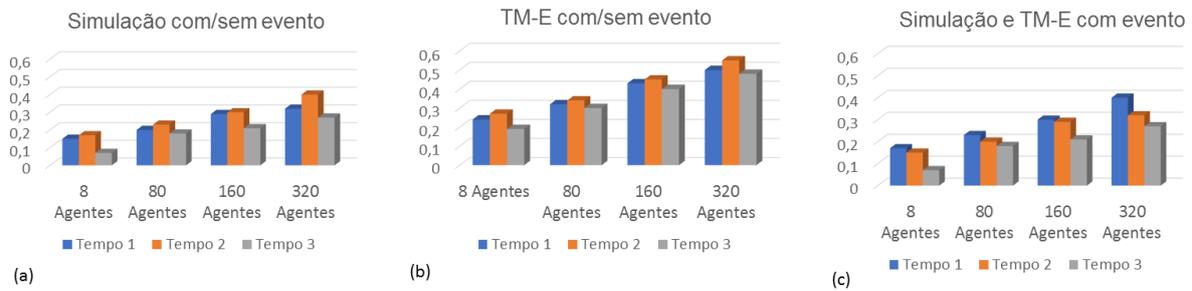


Figura 5.16 – Diferenças de densidades observadas nas três comparações relacionadas com evento  $\tau_1 = 1$  e  $\sigma_1 = 2$ .

como explicitado anteriormente. Nas análises utilizando as informações de posições, para o experimento que comparou a simulação contínua e a TM-E com evento, e com uma população de 320 agentes chegaram-se as seguintes diferenças, 0,28, 0,26 e 0,20 nos tempos de análises 1, 2 e 3, respectivamente.

A Figura 5.17 ilustra as imagens para as simulações com 80 agentes e 320 agentes nos 3 tempos das análises. As imagens (a) e (c) apresentam o resultado visual da simulação contínua com eventos e as imagens (b) e (d) demonstram as simulações com o método TM-E.

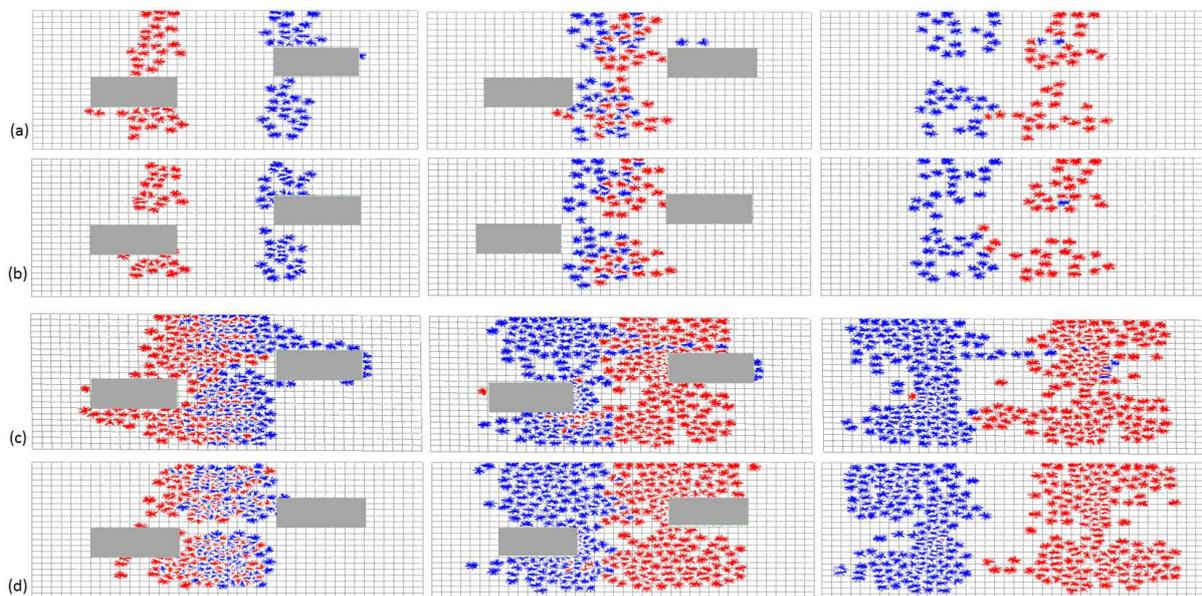


Figura 5.17 – Imagens das simulações (linhas a e c) e do método TM-E (linhas b e d) com 80 e 320 agentes, respectivamente, com evento  $\tau_1 = 1$  e  $\sigma_1 = 2$ .

Comparando os resultados dos testes  $\sigma_1 = 1$  (um obstáculo) e  $\sigma_1 = 2$  (dois obstáculos) percebe-se, um aumento das diferenças nas três verificações e em todas as populações nos testes com  $\sigma_1 = 2$ . No tempo 2, na análise TM-E com e sem evento, observa-se na população com 320 agentes e  $\sigma_1 = 2$ , um aumento na diferença de 0,28 quando comparado

ao mesmo experimento com  $\sigma_1 = 1$ . No tempo 1 para a população com 320 agentes, essa diferença foi superior a 0,20 na comparação dos resultados de  $\sigma_1 = 2$  com  $\sigma_1 = 1$  obtidos no experimento de simulação contínua com método TM-E com eventos. Estendendo essa consideração para a análise da simulação e do método TM-E com evento, observa-se que, tanto para o caso com  $\sigma_1 = 1$  quanto para o  $\sigma_1 = 2$ , as maiores diferenças ocorrem no *frame* da volta (tempo 1). Ou seja, o maior impacto ocorre exatamente no *frame* da volta e diminui no decorrer do tempo. Nessa mesma análise (simulação e método TM-E com evento) observa-se uma diferença máxima em relação as posições de 0,07, no tempo 1, para a população de 320 agentes.

### 5.3.2 Caso B: Investigação do impacto do evento $k$ tipo $\tau_k = 2$ (população) durante o avanço de tempo

Neste segundo caso de estudo, considerou-se um evento  $e_2$  do tipo  $\tau_k = 2$ , ou seja, uma nova população será incluída no ambiente durante a estimativa da multidão. Da mesma forma que no caso de estudo anterior, três comparações foram feitas: *i*) Simulação com e sem evento; *ii*) Método TM-E com e sem evento; e *iii*) Simulação e TM-E ambas com evento. Similarmente à última seção, a Figura 5.18 apresenta as definições dos tempos de evento e *frames* de análises.

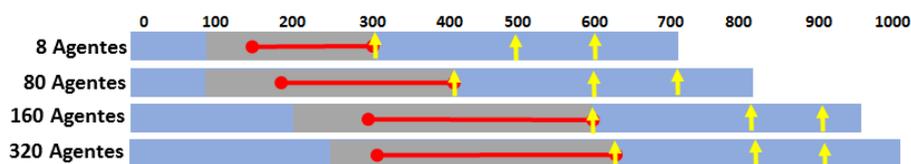


Figura 5.18 – As linhas mostram a configuração de cada população. Linhas horizontais vermelhas indicam o início e o fim de um evento, setas verticais amarelas apontam os *frames* de análise e as barras cinzas, o tempo em que o método TM-E acontece

Este evento é definido como  $e_2 = \{t_2, \Delta t_2, \tau_2, \vec{O}_2, \vec{A}_2\}$ , onde  $\tau_2 = 2$ ,  $\vec{O}_2 = \emptyset$  e  $\vec{A}_2 = \{a_2, \vec{p}_2, \vec{g}_2, \vec{v}_2\}$ , onde  $a_2 = 15\%$  do total da população,  $\vec{p}_2$  e  $\vec{g}_2$  são definidos no centro do ambiente virtual e com objetivo para a esquerda (veja agentes em preto na Figura 5.20) e  $\vec{v}_2 = 0,08$ . Como nos estudos de casos relatados na última seção, realizou-se as mesmas três comparações e a cada *frame* específico computaram-se as diferenças de posição e densidade. A Figura 5.19 apresenta as diferenças de densidades, o gráfico apresentando em (a) ilustra os resultados da simulação com e sem evento, (b) apresenta as diferenças de posição do método TM-E com e sem evento e (c) demonstra as diferenças da simulação e do método TM-E com evento. Neste estudo de caso, os eventos foram finalizados no tempo 1, justificando-se assim os maiores erros esperados, neste tempo, para os três experimentos. Cabe evidenciar que nos demais tempos de análise todos os erros diminuíram quando

comparados ao primeiro tempo de análise (momento de finalização do evento). Na última comparação (simulação e do método TM-E), para o caso com 320 agentes no tempo 3, observa-se uma redução de 0,16, quando comparado à diferença do tempo 1. Novamente pode-se constatar que quanto mais o tempo passa, após a finalização do evento, menores são as diferenças entre o método TM-E (posições estimadas com evento) e a simulação com evento. Ainda para a população com 320, nos experimentos utilizando as informações de posições, para o teste que comparou a simulação contínua e a TM-E com evento, obtiveram-se as seguintes diferenças, 0, 22, 0, 16 e 0, 14 nos tempos de análises 1, 2 e 3, respectivamente.

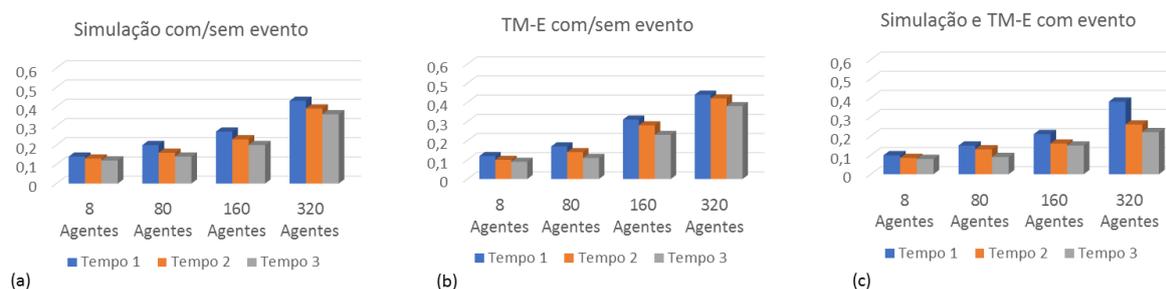


Figura 5.19 – Diferenças de densidades observadas nas três comparações relatadas, com evento  $\tau_1 = 2$

A Figura 5.20 demonstra o evento estudado. As linhas (a) e (b) ilustram resultados da simulação e TM-E com população de 80 agentes, enquanto as mesmas configurações com 320 agentes são apresentadas nas linhas (c) e (d)). Os agentes em preto são os novos, tratados como eventos do tipo  $e_2$  e iniciam no *frame* 200 e finalizam no *frame* 400 para 80 agentes, e, para 320 agentes, os *frames* de início e fim dos eventos são 250 e 600, respectivamente.

### 5.3.3 Caso C: Investigação do impacto do evento $k$ tipo $\tau_k = 3$ (obstáculos e população) durante o avanço de tempo

Para o terceiro experimento considerou-se um evento  $e_3$  do tipo  $\tau_3 = 3$ , ou seja, durante o avanço de tempo uma nova população (como descrito na Seção 5.3.2) e um obstáculo (como apresentado na Seção 5.3.1) serão inclusos no ambiente. Da mesma forma que para os testes  $\tau_k = 1$ , (obstáculos) descritos na Seção 5.3.1 nas análises da simulação com e sem evento (Figura 5.21(a)), e do método TM-E com e sem evento (Figura 5.21(b)) é possível perceber que os erros foram maiores no tempo 2, instante de finalização do evento, pois as diferenças causadas pelos eventos se propagam no decorrer do tempo e no tempo 3 tendem a diminuir. Por outro lado, a partir das análises da simulação e método com evento (Figura 5.21(c)) constata-se que os maiores erros ocorrem no tempo 1, instante

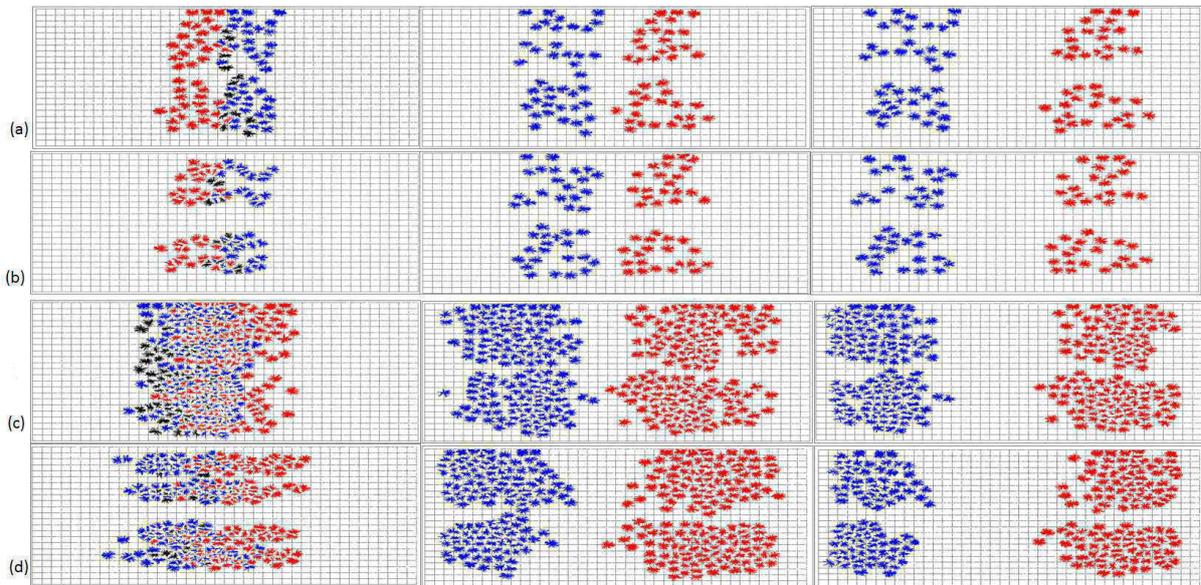


Figura 5.20 – Imagens das simulações (linhas a e c) e do método TM-E (linhas b e d) com 80 e 320 agentes, respectivamente, com evento  $\tau_1 = 2$

da finalização do avanço de tempo. As diferenças encontradas a partir da métrica de posições, para essa última comparação, obteve erros de 0,32; 0,24 e 0,22 nos tempos 1, 2 e 3, respectivamente, nas simulações com 320 agentes.

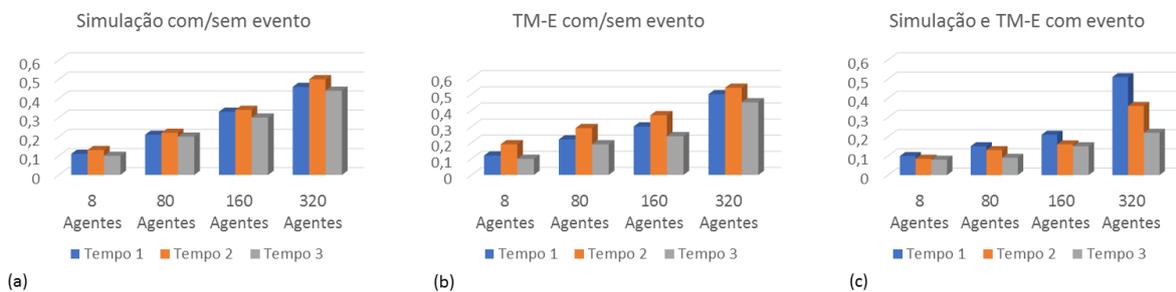


Figura 5.21 – Diferenças de densidades observadas nas três comparações relacionadas para eventos  $\tau_k = 3$

Ao final desses experimentos com eventos, constata-se que a maior diferença atingida foi de 0,5 em uma população de 320 agentes, de acordo com a métrica de densidade. Isso significa que, para realizar estimativas do comportamento futuro, o modelo proposto apresenta um erro médio de 50% de uma pessoa/m<sup>2</sup>, considerando regiões ocupadas. Observando as diferenças relativas a métrica de posições, o erro máximo foi de 0,32. Relembrando que nas avaliações com cenários estáticos (descritos na Seção 5.2) o erro máximo foi de 0,21. Assim, com os testes desta seção, reitera-se que, a partir do método TM-E, é possível prever o tempo futuro imediato de uma multidão, incluindo o tratamento de ocorrência de eventos.

Até o presente momento todos os ambientes foram elaborados e simulados computacionalmente, no entanto foi interesse desse trabalho verificar os resultados obtidos pelo método TM-E em situações reais. Assim, optou-se por filmar um cenário real com diferentes configurações e realizar experimentos objetivando comparar os dados obtidos com o método TM-E com os dados dos cenários reais, conforme discutido na próxima seção.

## 5.4 Experimentos com Cenários Reais

Para esses experimentos, filmou-se o comportamento das pessoas em um ambiente de 32 m<sup>2</sup> em cinco distintas configurações de cenário. A primeira configuração contou com 12 pessoas caminhando em um fluxo unidirecional da direita para a esquerda (Figura 5.22 (a)). Na segunda configuração de cenário, participaram 31 pessoas e, destas, 20 pessoas se locomoveram na direção horizontal, da esquerda para a direita, e 11 andaram na vertical de cima para baixo (Figura 5.22 (b)). No terceiro cenário, estáticos de pessoas (cada grupo ocupando uma área de 2m<sup>2</sup>, Além dos obstáculos, adicionaram-se 24) para fazerem o papel de obstáculos. Além dos obstáculos, adicionaram-se 24 pessoas com mesmo sentido e direção (Figura 5.22 (c)). A Figura 5.22 (d) apresenta o quarto cenário, que contou com 31 pessoas, 17 caminharam na direção horizontal da esquerda para a direita e 14 pessoas da direita para a esquerda. Por fim, no quinto cenário, participaram 24 pessoas que caminharam na direção horizontal e com sentidos contrários, conforme ilustra a Figura 5.22 (e). Ressalta-se que esses são os totais de pessoas em cada cenário. As pessoas tratadas como eventos estão inclusas nestes totais e serão detalhados a seguir.

De posse dos vídeos, realizaram-se os rastreamentos das trajetórias através do Tracker [9], disponível no VHLAB. As posições foram calculadas em coordenadas de mundo. Posteriormente, mapeou-se o ambiente real no *setup* do BioCrowds e configuraram-se os parâmetros relativos à população, às posições de origem, às posições de destino e ao tamanho dos obstáculos, segundo as informações dos vídeos. A velocidade média de cada agente foi atribuída de acordo com as trajetórias, para isso dividiu-se a distância percorrida pelo total de *frames* filmado no vídeo. Para cada um dos cinco cenários, apresentados na Figura 5.22, foram realizados os dois experimentos descritos a seguir.

*i) Contínuo* - Neste experimento, a simulação foi executada sem "avanços de tempo". Durante a execução, compararam-se as posições da simulação com as posições do vídeo, empregando-se a Equação 5.5. A diferença entre a simulação e o vídeo também foi analisada utilizando as informações de densidade, conforme a Equação 4.11.

*ii) Time Machine com Evento (TM-E)* - Neste experimento, o objetivo foi estimar as posições dos agentes em um tempo futuro e comparar com as posições do vídeo. Neste caso, a partir de um dado instante de tempo  $t$ , denominado *frame* de início, até um segundo instante  $t_1$  (*frame* da volta) as posições serão estimadas conforme o método detalhado

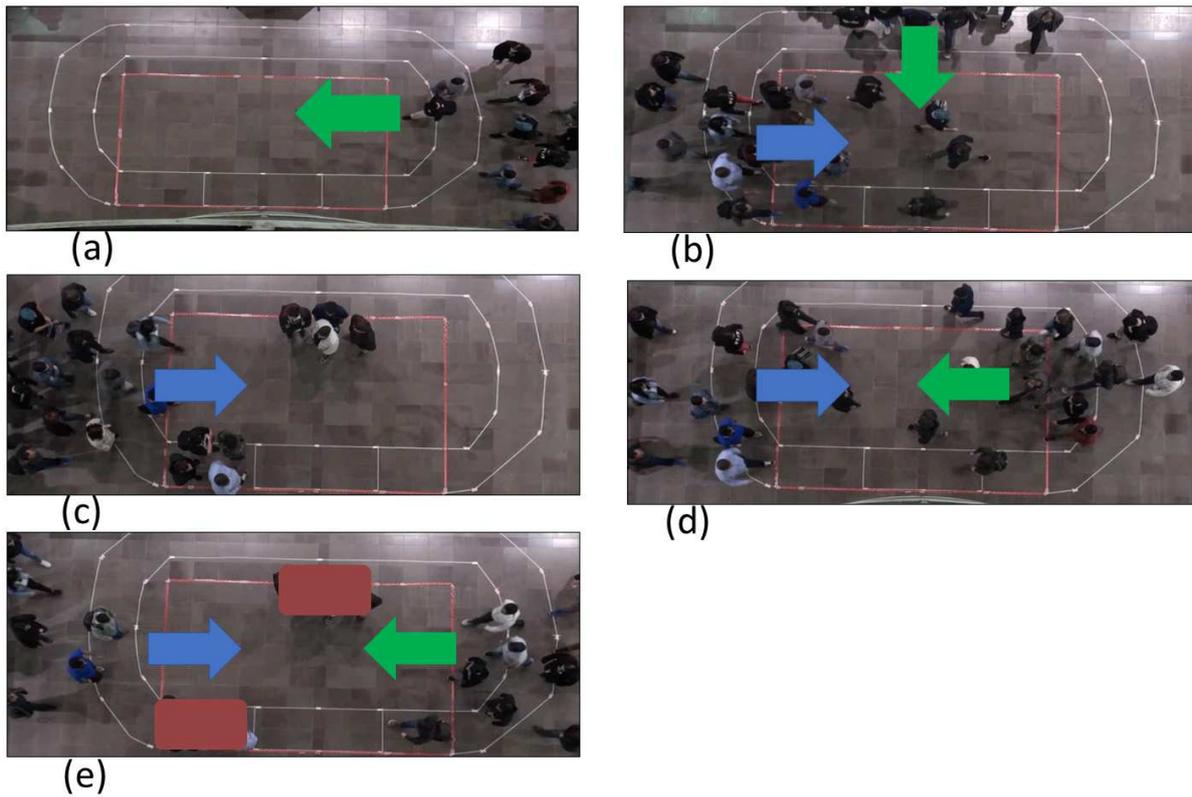


Figura 5.22 – Os cinco cenários reais utilizados para demonstrar o método. (a) Primeiro Cenário. (b) Segundo Cenário. (c) Terceiro Cenário. (d) Quarto Cenário. (e) Quinto Cenário

no Capítulo 4. Além disso, as pessoas que surgirem entre  $t$  e  $t_1$  serão tratadas como eventos ( $\tau_k = 2$ ), isto é, durante a estimativa, a cada ocorrência de evento as posições serão ajustadas conforme equações 4.9 e 4.10 (detalhadas na Seção 4.2). A Figura 5.23 exemplifica a entrada de 12 pessoas durante o intervalo de tempo do *frame* 60 ao *frame* 110, que neste experimento serão tratadas como evento ( $\tau_k = 2$ ).

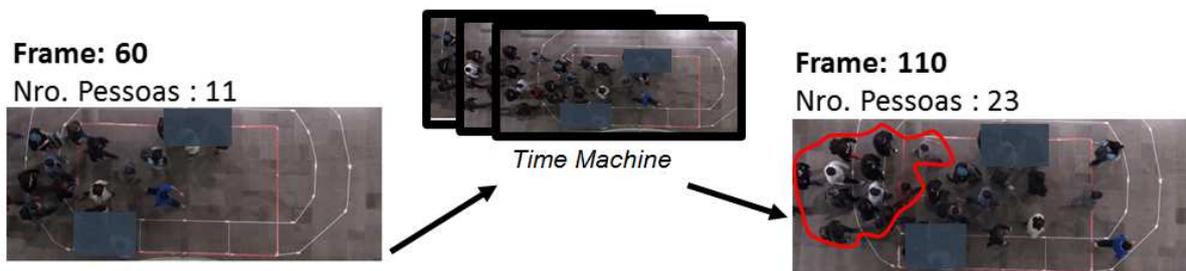


Figura 5.23 – Um exemplo de distribuição de pessoas no *frame* 60 (de acordo com a imagem à esquerda) e uma demonstração após 50 *frames* com um adicional de 12 pessoas (conforme o destaque em vermelho da figura à direita). A simulação TM-E considera esse adicional como evento

No que tange às simulações realizadas, cabe evidenciar que, ainda nos *frames* iniciais, foram observadas diferenças entre a simulação e o vídeo, apesar dos dados de entrada da simulação terem sido configurados iguais aos do vídeo. Isso acontece porque, já nos primeiros *frames* da simulação, os agentes podem fazer escolhas diferentes das pessoas na simulação. Na verdade, extrapolando este exemplo, dois grupos de pessoas reais, que partem das mesmas posições iniciais, podem evoluir diferentemente no tempo futuro, mesmo que seus objetivos finais sejam também os mesmos. Esse aspecto randômico da vida real é uma característica intrínseca desse tipo de simulação. Por exemplo, quando uma pessoa encontra uma pessoa mais lenta à sua frente, ela tenta desviar, em alguma direção possível, da pessoa mais lenta. Embora esse mesmo comportamento também ocorra na simulação, o momento de início do desvio e a direção a seguir (desvio pela direita ou pela esquerda) escolhidos pelo agente podem ser diferentes dos escolhidos por uma pessoa no mundo real. Assim, é razoável esperar diferenças entre o mundo real e a simulação.

Nos testes realizados, a simulação foi inicializada com os dados do *tracking* no instante escolhido para iniciar a estimativa ( $t$ ). O *frame* de início ( $t$ ), o *frame* da volta ( $t_1$ ), os instantes das ocorrências de eventos ( $t_e$ ), o tipo de evento ( $\tau$ ), o número de pessoas tratadas como eventos ( $a_n$ ) (no caso da ocorrência de eventos  $\tau = 2$ ) e a direção da movimentação são apresentados na Tabela 5.2.

Em todos os cenários, as diferenças entre o vídeo e a simulação foram avaliadas em cinco instantes de tempo. Os dois primeiros instantes são dados na Tabela 5.2 e os demais instantes das análises aconteceram nos *frames* 160, 200 e 240, para todos os cenários.

Tabela 5.2 – Dados dos experimentos. *Frame* de pause  $t$ , o *frame* da volta  $t_1$ , tempo de ocorrência dos eventos e o sentido  $\tau_k = 2$

	$t_1$	$t_2$	Dados dos Eventos $e_k$	Sentido
1º Cenário	60	130	sem eventos	
2º Cenário	80	130	1 Evento ( $e_1$ ): $\tau_{e_1} = 2$ $t_{e_1} = 90, a_{e_1} = 5$	Cima para baixo
3º Cenário	70	140	1 Evento ( $e_1$ ): $\tau_{e_1} = 2$ $t_{e_1} = 130, a_{e_1} = 9$	Esquerda para a direita
4º Cenário	60	130	2 Eventos ( $e_1$ ) e ( $e_2$ ): $\tau_{e_1} = 2$ $t_{e_1} = 70, a_{e_1} = 4$ $t_{e_2} = 90, a_{e_2} = 2$	Esquerda para a direita
5º Cenário	60	130	1 Evento ( $e_1$ ): $\tau_{e_1} = 2$ $t_{e_1} = 70, a_{e_1} = 3$	Direita para a esquerda

O método *Time Machine* (sem eventos) não foi executado nestes cenários, uma vez que o interesse foi avaliar o desempenho da proposta TM-E (TM com Eventos) em cenários reais. Na sequência serão apresentados os resultados provenientes das métricas

de posição e de densidade obtidos nas comparações entre simulações (Contínua e TM-E) com vídeos reais.

#### 5.4.1 Primeiro Cenário de Estudo: Fluxo Unidirecional (Figura 5.22(a))

Neste primeiro estudo de caso, calcularam-se a média das diferenças das posições individuais e a média das diferenças de densidade entre os dados do vídeo e da simulação contínua. Ainda, verificou-se as diferenças do vídeo e da simulação com TM-E. A Figura 5.24 (a) apresenta as diferenças relativas às posições individuais. Os resultados do experimento contínuo são apresentados na linha azul e os resultados do experimento TM-E são expostos na linha cinza. É possível verificar que a diferença entre os dois experimentos ocorreu no *frame* da volta (110) chegando a 0,15. O gráfico referente à densidade é apresentado na Figura 5.24(b), a linha azul demonstra os resultados da análise contínua e as linha cinza apresentam os resultados da análise TM-E. Neste gráfico, é possível observar resultados equivalentes obtidos nos experimentos contínuo e TM-E. À direita da Figura 5.24, são apresentadas capturas de tela do *frame* 110 do vídeo (Figura 5.24(c)), da simulação contínua (Figura 5.24(d)) e da simulação com TM-E (Figura 5.24(e)). Optou-se por demonstrar esse instante devido ao interesse em apresentar visualmente os resultados e, porque, neste *frame*, ocorrem os reposicionamentos e as diferenças tendem a ser maiores, quando comparadas ao vídeo, do que nos demais frames. Esse vídeo encerrou no *frame* 180 e, portanto, não foi possível computar posições nos *frames* 200 e 240.

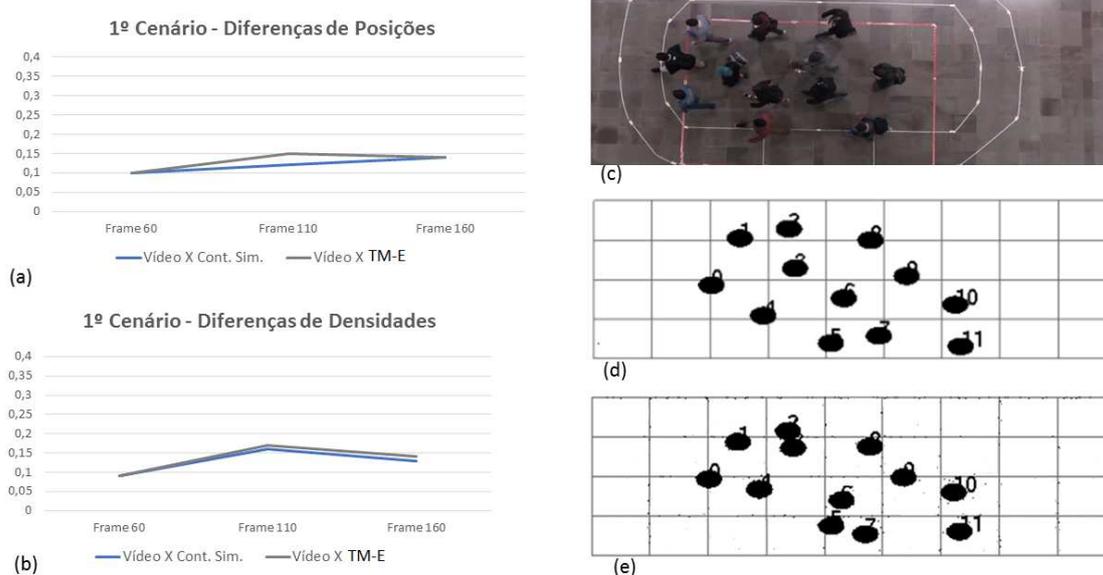


Figura 5.24 – Resultados do primeiro caso de estudo. (a) Diferenças de posições. (b) Diferenças de densidades. (c), (d) e (e) Imagem do *frame* 110 do vídeo e da simulação contínua e da simulação com TM-E, respectivamente

#### 5.4.2 Segundo Cenário de Estudo: Fluxo Bidirecional e Sentidos Opostos (Fig. 5.22(b))

Neste contexto, os dados de entrada das simulações, como posições de origem e destino estão configurados de acordo com o segundo vídeo. Realizaram-se os experimentos (Contínuo e TM-E) comparando as diferenças médias de posições e de densidades nos cinco *frames* (80, 130, 160, 200 e 240).

Para este teste a simulação foi inicializada com os dados do vídeo no *frame* 80 ( $t$ ), eliminando as diferenças de comportamento entre a simulação e o vídeo real. Neste caso, os experimentos iniciaram com 26 pessoas. A Figura 5.25 (e) demonstra as diferenças em relação a posição na análise contínua (linha azul) e na análise da TM-E (linha laranja) e a Figura 5.25 (f) apresenta as diferenças relativas às densidades obtidas nos experimentos contínuo e TM-E. Percebe-se que no *frame* da volta (130) os erros em relação as posições, do experimento TM-E (e), foram de 0,12, sendo bem próximo ao erro da simulação contínua que foi de 0,11. Nos *frames* seguintes os erros, obtidos no método TM-E, cresceram em até 0,09, em relação aos erros dos *frames* anteriores.

Observando-se as diferenças em relação à densidade (f), foi possível constatar que os valores também aumentaram após o *frame* de pausa em até 0,10, visto que, conforme explicado anteriormente, a tomada de decisões dos agentes difere da tomada de decisão dos seres humanos.

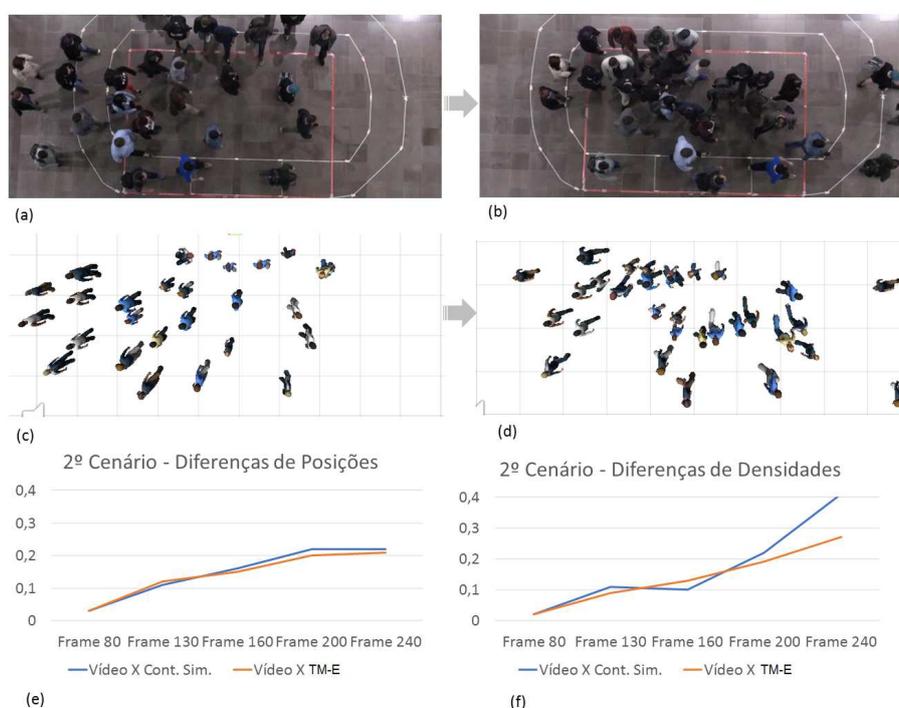


Figura 5.25 – Capturas de tela do segundo cenário. (a) *Frame*  $t$  do vídeo. (b) *Frame*  $t_1$  do vídeo (c) *Frame*  $t$  do experimento TM-E. (d) *Frame*  $t_1$  do experimento TM-E

As linhas um e dois da Figura 5.25 apresentam as capturas de telas referente ao instante  $t$  do vídeo (a) e da simulação TM-E (c). O instante do *frame* da volta do vídeo e da simulação TM-E são apresentados em (b) e (e), respectivamente. Ao comparar-se o resultado qualitativo oriundo da *Time Machine* com Evento, no *frame* da volta ( $t_1$ ), apresentando na Figura 5.25 (d), percebe-se uma coerência em relação ao vídeo (Figura 5.25) (b).

### 5.4.3 Terceiro Cenário de Estudo: Fluxo Unidirecional com Obstáculo (Figura 5.22(c))

Assim como realizado nos cenários anteriores, para este estudo, executaram-se os experimentos contínuo e TM-E, com o intuito de comparar as posições e as densidades, em diferentes momentos (nos *frames* 70, 140, 160, 200 e 240). Neste caso, esse cenário foi inicializado no *frame* 70 com 15 agentes. Durante a execução do método TM-E, ocorreram eventos do tipo  $\tau = 2$  e, até o *frame* 140, entraram mais nove pessoas, o instante da ocorrência deste evento foi apresentado na Tabela 5.2.

Através da Figura 5.26 (e) é possível verificar que o erro, relativo às posições para o experimento TM-E (linha laranja), ao final da estimativa (*frame* 140), foi de 0,12. Observando-se ainda os resultados do experimento TM-E, pode-se afirmar que as diferenças de posições aumentaram em média 0,17 nos próximos instantes de análise, pois, após o instante  $t_1$ , os obstáculos impactaram mais pessoas. Em relação as diferenças de densidades foi possível observar uma diferença de 0,1 no *frame* da volta (Figura 5.26 (f)). É

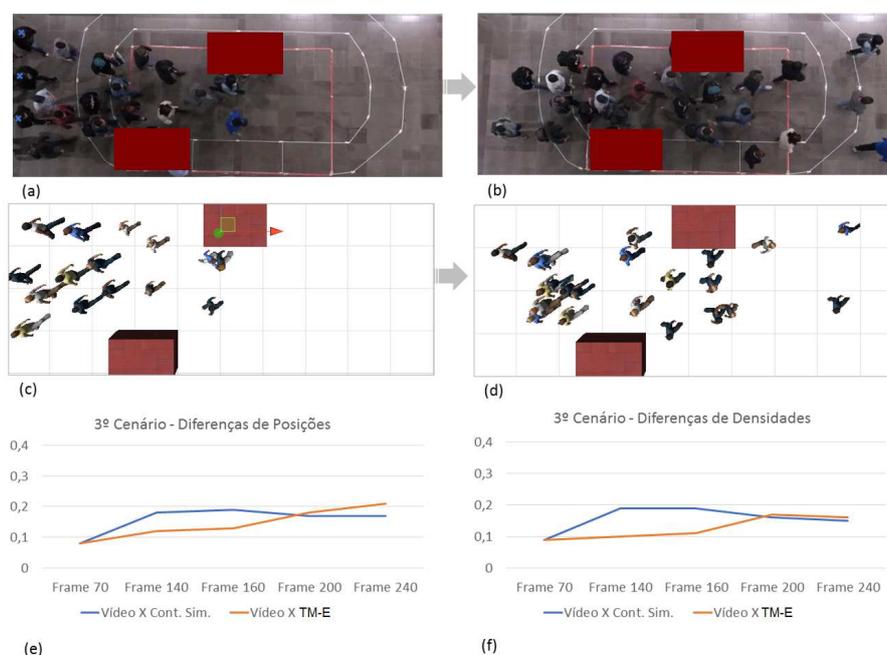


Figura 5.26 – Capturas de tela do terceiro cenário. (a) *Frame*  $t$  do vídeo. (b) *Frame*  $t_1$  do vídeo (c) *Frame*  $t$  do Experimento TM-E. (d) *Frame*  $t_1$  do Experimento TM-E.

importante lembrar que, neste teste, o avanço de tempo ocorreu do *frame* 70 ao 140 e a simulação foi inicializada com dados do vídeo no *frame* 70. As Figuras 5.26(a) e (b) apresentam o *frame* 70 e 140 do vídeo. Da mesma maneira, é possível observar o instante inicial da simulação na Figura 5.26 (c). As três últimas pessoas a entrar no vídeo (salientadas com X em (a)) ainda não haviam sido identificadas pelo *tracker*, por isso não constam na imagem da simulação. Além disso, a Figura 5.26 (d) ilustra o instante da finalização da estimativa e o retorno da simulação (*frame* 140).

#### 5.4.4 Quarto Cenário de Estudo: Fluxo Bidirecional (Figura 5.22(d))

O quarto cenário refere-se ao vídeo com 32 pessoas com fluxos em sentidos opostos (esquerda para direita e vice versa) e sem obstáculos. Neste caso, as simulações foram inicializadas com dados do *frame* 60 ( $t$ ), do vídeo, e as estimativas ocorreram deste instante até o *frame* 130 ( $t_1$ ). Durante o experimento TM-E, ocorreram eventos do tipo  $\tau = 2$  e foram incluídas seis pessoas durante a estimativa. O instante de ocorrência destes eventos estão detalhados na Tabela 5.2. A Figura 5.27 (e) ilustra as diferenças nas posições em tempos específicos. No experimento TM-E, observa-se que nos *frames* 130 e 160 ocorreram os maiores erros chegando a 0,25 e 0,28, respectivamente. No *frame* 130 tem-se o resultado da estimativa, onde ocorrem ajustes de reposicionamento, e também neste intervalo de tempo (do *frame* 130 ao *frame* 160) acontecem os cruzamentos entre os fluxos.

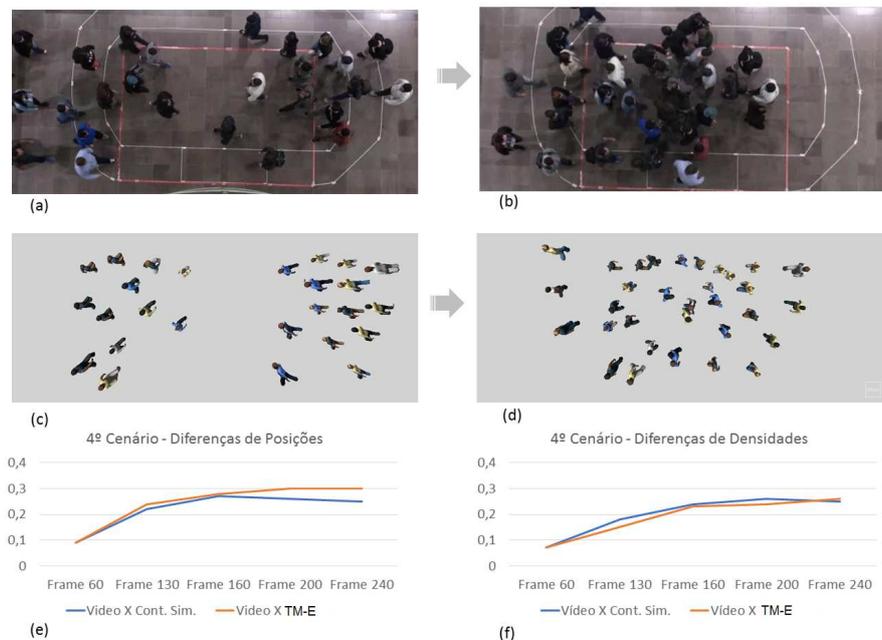


Figura 5.27 – Capturas de tela do quarto cenário. (a) *Frame*  $t$  do vídeo. (b) *Frame*  $t_1$  do vídeo. (c) *Frame*  $t$  do experimento TM-E. (d) *Frame*  $t_1$  do experimento TM-E

As imagens (a) e (b) da Figura 5.27 ilustram os *frames* 60 e 130, respectivamente, e as imagens (c) e (d) apresentam a simulação com o experimento TM-E nestes mesmos *frames*. Percebe-se a coerência visual além dos resultados quantitativos em (e) e (f).

#### 5.4.5 Quinto Cenário de Estudo: Fluxo Bidirecional com Obstáculos (Figura 5.22(e))

Por fim, o quinto cenário apresenta 24 pessoas, com fluxo bidirecional, mas com adicional de dois obstáculos (as dimensões dos obstáculos foram informadas no início desta seção). Da mesma forma que nos cenários anteriores, neste contexto, computaram-se as diferenças entre a simulação e o vídeo com a simulação inicializada com dados do *frame* 60 ( $t$ ). Durante a execução do método TM-E, ocorreram eventos ( $\tau = 2$ ) e foram inclusas três pessoas (conforme apresentado na Tabela 5.2). Na Figura 5.28 (e) demonstra as diferenças em relação às posições. Nos resultados do experimento TM-E (linha laranja) é interessante observar que o erro no *frame* da volta foi de 0,2, um erro relativamente alto, quando considerado os erros do cenários anteriores, mas justifica-se pelas estimativas serem próximas aos obstáculos e também ser o momento do cruzamento. Observa-se que as diferenças relativas às posições e de às densidade (conforme Figuras 5.28(e) e (f)) estabilizam-se nos dois últimos *frames* de análise.

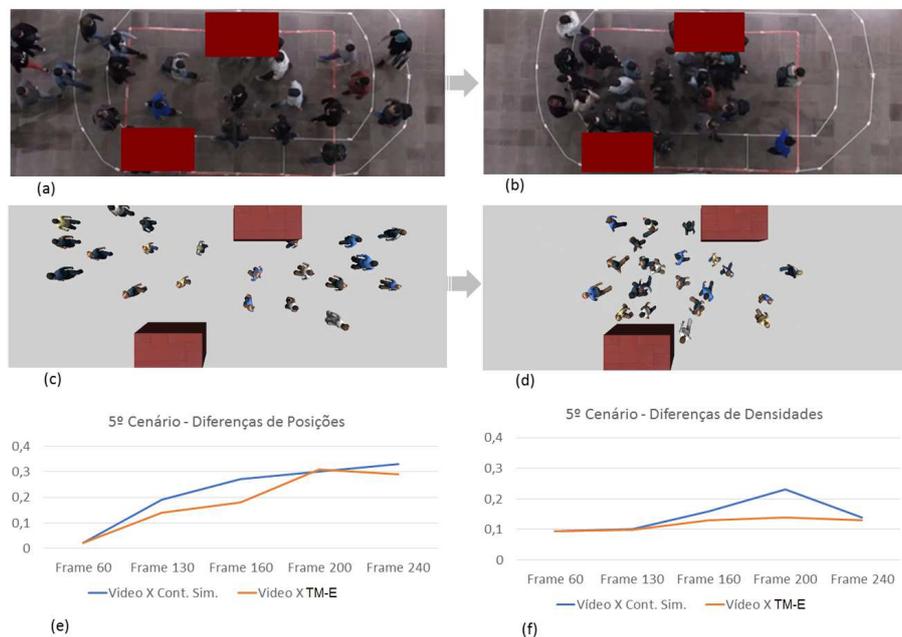


Figura 5.28 – Informações do quinto cenário. (a) *Frame*  $t$  do vídeo. (b) *Frame*  $t_1$  do vídeo (c) *Frame*  $t$  do Experimento TM-E. (d) *Frame*  $t_1$  do Experimento TM-E

A Figura 5.28 (a) e (b) apresentam os *frames* 60 e 130 do vídeo e as imagens (c) e (d) demonstram o experimento TM-E também nos *frames* 60 e 130. Ressalta-se que a

imagem (d) é o resultado gerado pelo TM-E, de 24 pessoas entre obstáculos e no momento do cruzamento, considera-se este resultado similar ao vídeo.

#### 5.4.6 Análises dos Experimentos

Nesta seção, são apresentadas as diferenças relativas às posições agrupadas por experimentos, a fim de relacionar os resultados com a complexidade dos cenários. A Figura 5.29(a) ilustra as diferenças de posições entre o vídeo e a simulação nos cinco cenários (Vídeo 1, Vídeo 2, Vídeo 3, Vídeo 4 e Vídeo 5) obtidas no teste em que a simulação foi inicializada com os parâmetros do vídeo. A Figura 5.29(b) ilustra as diferenças de posição entre o experimento TM-E e o vídeo obtidas com os testes em que a simulação iniciou no tempo  $t$ . Nestes experimentos, as diferenças foram observadas em cinco instantes de tempo sendo:  $t$  (*frame* de início),  $t_1$  (*frame* da volta), *frame* 160, *frame* 200 e *frame* 240 ( $t_2$  e  $t_3$  para cada cenário são especificados na Tabela 5.2)

Em relação às diferenças obtidas com a análise contínua (posições das simulações contínuas comparadas com as posições dos vídeos), observa-se que no decorrer do tempo os erros aumentam ou estabilizam. Os erros crescem em algumas situações de desvio (de obstáculo ou pessoas), uma vez que o método não busca replicar as decisões das pessoas, mas apenas chegar aos seus objetivos. A partir do *frame* 200 os erros decrescem ou estabilizam devido aos agentes estarem próximos aos objetivos, e conseqüentemente diminuindo as diferenças de posições quando comparadas ao vídeo. As maiores diferenças são percebidas no quarto cenário (vídeo 4), que apresenta o maior número de pessoas e também ocorrem cruzamentos. As menores diferenças ocorrem no primeiro cenário (vídeo 1) por ser menos denso, e onde o percurso foi menor (finalizado no *frame* 180) e com um único fluxo.

O experimento TM-E estima as posições dos agentes a partir do *frame* de início ( $t$ ) até o *frame* da volta ( $t_1$ ) da simulação. A Figura 5.29(b) apresenta as diferenças das posições entre o vídeo e as simulações do experimento TM-E com o método inicializado com dados do *frame* ( $t$ ). Constata-se que as maiores diferenças em todos os *frames* de análise são verificadas no quarto cenário (vídeo 4). O segundo maior erro alcançado em  $t_1$  (*frame* da volta) foi observado no quinto cenário, e também percebe-se uma elevação no erro nos próximos *frames* de análise, chegando a 0,28, no *frame* 200, por causa da presença dos obstáculos neste cenário. Essa particularidade também é notada no terceiro cenário, o qual apresentou um aumento nas diferenças a partir de  $t_1$  com tendência de crescimento até o *frames* 200, decorrente dos obstáculos. No instante  $t_1$  do segundo cenário, o erro foi de 0,13 sendo o terceiro maior erro, ocasionado pelos cruzamentos que estavam acontecendo neste instante.

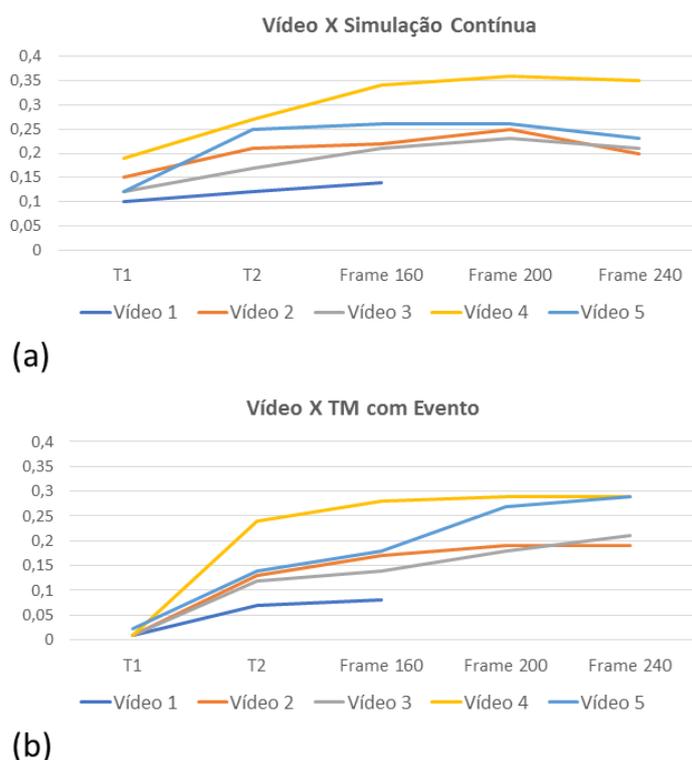


Figura 5.29 – Diferenças agrupadas por experimento com as simulações inicializadas no instante  $t$ . (a) Resultados das diferenças entre as posições do vídeo e as posições da simulação contínua. (b) Resultados das diferenças de posições entre TM-E e o vídeo

Considerando as diferentes configurações de cenários, o intervalo médio usado nas análises, de 180 *frames* (60 a 240), e o avanço de tempo de 50 *frames* nos dois primeiros cenários e de 70 *frames* nos três últimos cenários, é possível afirmar que o método proposto:

*i)* apresentou um erro máximo de aproximadamente 0,35, no quarto cenário, conforme observando na Figura 5.29(b), correspondente a diferença média de posições ao finalizar uma estimativa;

*ii)* alcançou um erro máximo de 0,4, relativo às diferenças médias de densidade das áreas ocupadas;

*iii)* o método demonstrou um bom desempenho sendo uma ferramenta útil para estimar comportamentos futuros de multidões. As particularidades observadas em relação aos desvios de obstáculos são inerentes à metodologia para movimentação utilizada no BioCrowds, conforme detalhando na Seção 2.3.

Para apurar a coerência entre as métricas de densidade e de posição, verificou-se a correlação entre as diferenças de densidades e de posições resultantes do experimento Contínuo (Figura 5.30(a)), bem como, a correlação destas mesmas métricas para as veri-

ficações com TM-E (Figura 5.30(b)). Também realizou-se a correlação entre os erros de todos os cenários e *frames* de análise (Figura 5.30(c)). Para os experimentos Contínuo e TM-E, os resultados das correlações foram 0,60 e 0,65, respectivamente. Realizando uma análise de correlação de todas as diferenças em ambos os experimentos, o resultado foi de 0,63. Assim, afirma-se que, quando as diferenças de posições variam, as diferenças de densidades também variam.

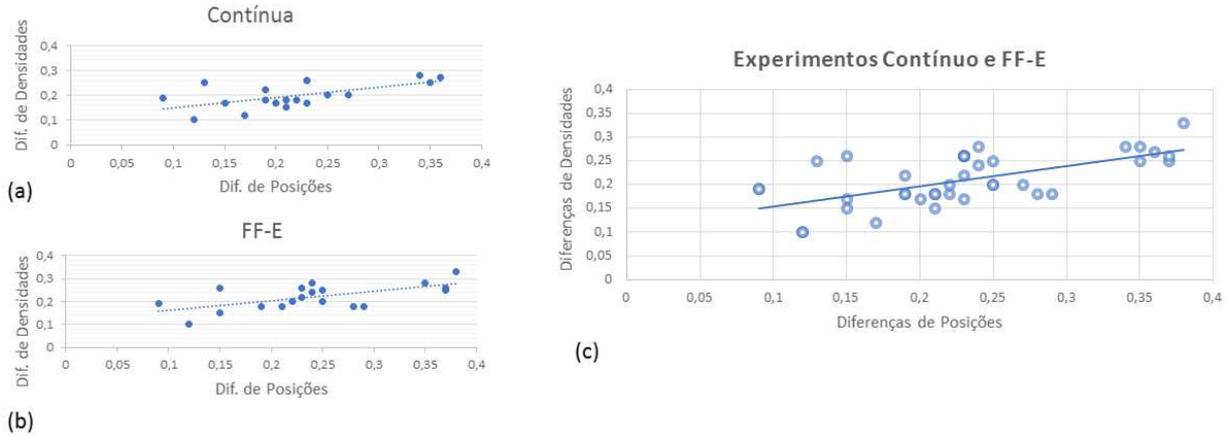


Figura 5.30 – Correlação entre as diferenças de densidades e as diferenças de posições. (a) Correlação entre as diferenças de posições e densidades obtidas no experimento Contínuo. (b) Correlação entre as diferenças de posições e densidades do método TM-E. (c) Correlação entre as diferenças de posições e densidades obtidas em ambos os experimentos

## 6. CONSIDERAÇÕES FINAIS

Esse trabalho teve como objetivo prever o comportamento de multidão em tempos futuros a partir do modelo *Time Machine*. A ideia principal consiste no desenvolvimento de uma nova abordagem capaz de identificar características de multidões, analisá-las e prever o comportamento de uma multidão em um tempo futuro. Na fase de prospecção do modelo, levantou-se a hipótese de propor a previsão baseada na simulação de alguns agentes. Para tanto implementou-se o método com líderes. A partir de experimentos com esse método, foi possível constatar que esta metodologia forneceu uma previsão razoável da distribuição futura de uma multidão. Ao analisar-se as diferenças em relação às posições (obtidas através da Equação 4.2, que calcula o erro baseado nas posições dos agentes), obteve-se um erro de 0,80 durante o avanço de tempo de 8,33 segundos, com 320 indivíduos em um ambiente complexo (com quatro obstáculos).

No método *Time Machine* com Estimativas, as posições prévias foram obtidas pela técnica de *PDR*. Percebeu-se que os resultados desta técnica geraram uma boa estimativa, mas que não considerava as reduções de velocidades e desvio de direção que normalmente ocorrem, por exemplo durante um cruzamento. Assim, incorporou-se as informações do ambiente e das interações entre os personagens. Ao observar os resultados, pode-se constatar que:

(i) para os testes realizados com variação populacional entre 8 e 320 agentes em quatro casos de estudos com diferentes configurações de ambiente (sem obstáculos, com dois, quatro e seis obstáculos), concluiu-se que o modelo gerou as estimativas durante um avanço de tempo de 8,33 segundos com um erro relativo às posições de 0,25.

(ii) ao comparar os erros obtidos na *Time Machine* com Líder e na *Time Machine* com Estimativa, pode-se afirmar que esse último método mostrou-se mais eficiente, apresentando redução nos valores dos erros. A seguir, serão listadas as reduções em cada cenário para as populações 8, 80, 160 e 320, quando realizada a subtração dos valores obtidos no método com líder pelos valores da TM. a) Cenário sem obstáculos: as reduções foram de 0,04; 0,18; 0,31 e 0,20; b) Cenário com dois obstáculos: observou-se diminuições de 0,18; 0,23; 0,24 e 0,66; c) Cenário com quatro obstáculos: (onde em ambos os modelos ocorreram as maiores diferenças) os erros obtidos, com a TM com Estimativas, foram inferiores à 0,13; 0,21; 0,76 e 0,56 quando comparados ao método com líder; e d) Cenário com seis obstáculos: constatou-se reduções de 0,08; 0,10; 0,14 e 0,26.

(iii) visando testar a robustez da *Time Machine*, adicionaram-se eventos durante o avanço de tempo. Ao analisar os resultados provenientes da TM com evento (TM-E), o erro

máximo atingido foi de 0,32 para a simulação com 320 agentes com a inclusão de eventos  $\tau = 3$  (obstáculos e população).

(iv) ao verificar os resultados gerados com a *Time Machine* (com estimativas e eventos) inicializada com as informações de cenários reais, conclui-se que, para as estimativas realizadas durante um avanço de tempo de 2,34 segundos com 31 pessoas distribuídas em fluxos opostos, o erro alcançado ao final da estimativa ( $t_2$ ) foi de 0,24. Considerando o cenário com dois obstáculos e 24 pessoas com sentidos contrários, o erro foi de 0,15 no segundo instante de análise ( $t_2$ ). Neste caso, a quantidade de pessoas e o momento de finalização do avanço de tempo, se este ocorrer, por exemplo, durante um cruzamento de fluxos, impacta estimativa das posições individualizadas. Da mesma forma, analisando-se os resultados de densidades obtidos nos mesmos estudos e instantes de análises supracitados, as diferenças relativas a densidades foram inferiores a 0,2 para o caso de estudo com 31 pessoas e de 0,15 para o cenário com 24 pessoas.

Conforme estudos apresentados no estado da arte, o modelo proposto descrito neste trabalho é inovador e pode prever as posições futuras com um bom desempenho, no entanto, outros estudos se fazem necessários para aprimorá-lo, tais como:

1. Utilizar técnicas de *Machine Learning* para aprender a complexidade do ambiente, bem como as interações entre pessoas, pois o atual modelo, após vários experimentos de simulações, utilizou a distribuição de Weibull, que apresentou melhor aderência às análises para a redução de velocidade. No entanto, essas análises podem ser aprimoradas, a fim de melhorar os ajustes realizados durante as estimativas. A própria predição do comportamento futuro poderá ser realizada utilizando técnicas de *Machine Learning* para reconhecimento das características de multidões e predições futuras.

2. Incluir o modelo TM em outro simulador, tais como CrowdSim ou Orca, e comparar com os resultados obtidos com o simulador BioCrowds. Isso é válido pois esses simuladores apresentam formas de prevenção de colisão diferentes daquelas utilizadas no BioCrowds. Por exemplo, no caso do ORCA apresentado na Seção 2.4, a prevenção de colisão é realizada restringido as velocidades que podem causar colisão. Assim, os comportamentos dos agentes poderiam ser mais realista do que o resultado do BioCrowds, onde os agentes apenas evitam colisão quando chegam bem perto de seus vizinhos.

3. Incorporar outras possibilidades de eventos, como por exemplo, quando o parâmetro  $\tau = 1$  verificar o impacto de obstáculos com contornos irregulares, bem como, para os eventos  $\tau = 2$ , os eventos podem considerar acontecimentos como um incêndio e incluir contágio de emoções.

4. Expandir os testes com vídeos reais empregando outros cenários e outras configurações de população. Adicionalmente, seria interessante testar a TM-E com cenários complexos utilizados na literatura, tais como os ambientes empregados por Berseth e colegas [6], bem como, utilizar trajetórias de multidões disponibilizados por pesquisadores,

como por exemplo, os vídeos reais e as trajetórias das pessoas disponibilizados por Favaretto e colegas [22].

A seguir serão listadas as publicações obtidas durante o andamento do doutorado.

## 6.1 Publicações

Nesta seção é apresentada a relação de trabalhos publicados durante o período de doutorado, além desses trabalhos a seguir relacionados.

1. *An Experience-Based Approach to Simulate Virtual Crowd Behaviors Under the Influence of Alcohol*. Esse artigo apresenta um *framework* para simular comportamentos heterogêneos, especificadamente relacionados a comportamentos de pessoas alcoolizadas [15].
2. *A Model to Compute People Disturbance in Crowds*. Este estudo apresenta uma técnica para identificar como a interferência durante o deslocamento em multidão impacta a velocidade [20].
3. *Preserving the Features of Crowd Motion in Fog of War Areas in Games*. Neste trabalho elaborou-se um método para manter os comportamentos realísticos em cenas que são executadas em *background* com foco em jogos [17].
4. *Fast-Forwarding Crowd Simulations*. O foco desta pesquisa foi possibilitar avanços de tempo em simulação de multidão. Com base nas características das multidões, calcula-se a variação esperada das velocidades, essa descoberta possibilitou avançar a simulação de multidão em um tempo no futuro [18].
5. *Predicting Future Crowd Motion Including Event Treatments*. Este estudo apresentou a predição de tempo futuro considerando a ocorrência de eventos, mantendo um compromisso entre o tempo de execução e o desempenho [19]. [57]

## REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Bakar, N.A.A., Adam, K., Majid, M.A., Allegra, M.: A simulation model for crowd evacuation of fire emergency scenario. In: International Conference on Information Technology (ICIT). pp. 361–368 (2017)
- [2] van den Berg, J., Lin, M., Manocha, D.: Reciprocal velocity obstacles for real-time multi-agent navigation. In: IEEE International Conference on Robotics and Automation. pp. 1928–1935 (2008)
- [3] van den Berg, J., Guy, S., Lin, M., Manocha, D.: Reciprocal n-Body Collision Avoidance, vol. 70 (2011)
- [4] Berlonghi, A.E.: Understanding and planning for different spectator crowds. *Safety Science* 18(4), 239 – 247 (1995)
- [5] Berseth, G., Kapadia, M., Faloutsos, P.: Steerplex: Estimating scenario complexity for simulated crowds. In: International Conference of Motion on Games. pp. 45:67–45:76. ACM, New York, NY, USA (2013)
- [6] Berseth, G., Usman, M., Haworth, B., Kapadia, M., Faloutsos, P.: Environment optimization for crowd evacuation. *Computer Animation and Virtual Worlds* 26(3-4), 377–386 (Jun 2015)
- [7] Bicho, A.L., Rodrigues, R.A., Musse, S.R., Jung, C.R., Paravisi, M., Magalhães, L.P.: Simulating crowds based on a space colonization algorithm. *Computers and Graphics* 36(2), 70 – 79 (Oct 2012)
- [8] Bicho, A.L.: Da modelagem de plantas á dinâmica de multidões: um modelo de animação comportamental bio-inspirado. (tese de doutorado), Universidade Estadual de Campinas - UNICAMP, Campinas (2009)
- [9] Bins, J., Dihl, L.L., Jung, C.R.: Target tracking using multiple patches and weighted vector median filters. *Journal of Mathematical Imaging and Vision* 45(3), 293–307 (Mar 2013)
- [10] Borges, F.N.A., Pelachaud, C., Musse, S.: Giving emotional contagion ability to virtual agents in crowds. In: International Conference Intelligent Virtual Agents - IVA (2017)
- [11] Bosse, T., Hoogendoorn, M., Klein, M.C.A., Treur, J., van der Wal, C.N.: Agent-Based Analysis of Patterns in Crowd Behaviour Involving Contagion of Mental States, p. 677 (2011)

- [12] Braun, A., Musse, S.R., Oliveira, L.P.L.d., Bodmann, B.E.J.: Modeling individual behaviors in crowd simulation. In: International Conference on Computer Animation and Social Agents (CASA). p. 143 (2003)
- [13] Capin, T., Pandzic, I., Thalmann, N., Thalmann, D.: A dead-reckoning algorithm for virtual human figures. *Virtual Reality Annual International Symposium 1*, 161–169 (Nov 1997)
- [14] Cassol, V.J., Testa, E.S., Jung, C.R., Usman, M., Faloutsos, P., Berseth, G., Kapadia, M., Badler, N.I., Musse, S.R.: Evaluating and optimizing evacuation plans for crowd egress. *IEEE Computer Graphics and Applications 37*(4), 60–71 (Oct 2017)
- [15] Cassol, V., Dal Bianco, M.C., Carvalho, A., Brasil, J., Monteiro, M., Musse, S.: An experience-based approach to simulate virtual crowd behaviors under the influence of alcohol pp. 124–127 (Aug 2015)
- [16] Challenger, Rose; Clegg, C.R.M.: Understanding Crowd Behaviours: Guidance and Lessons Identified. The Cabinet Office Emergency Planning College, York, UK (2009)
- [17] Dal Bianco, C.M., Braun, A., Brasil, J., Musse, S.R.: Preserving the motion features in nonavoiding collision crowds. *Computer in Entertainment 15*(3), 2:1–2:15 (Apr 2017)
- [18] Dal Bianco, C.M., Braun, A., Musse, S.R., Jung, C., Badler, N.: Fast-Forwarding Crowd Simulations, pp. 208–217. *Springer International Publishing*, Cham (2016)
- [19] Dal Bianco, C.M., Musse, S.R., Braun, A., Caetani, R.P., Jung, C., Badler, N.: Predicting Future Crowd Motion Including Event Treatment, pp. 101–104. *Springer International Publishing*, Cham (2017)
- [20] Dal Bianco M. C., Brasil J. O, B.A., Musse, S.R.: A model to compute people disturbance in crowds. In: International Conference Motion in Games (2015)
- [21] Dutra, T.B., Cavalcante-Neto, J.B., Vidal, C.A., Musse, S.R.: A multipotential field model for crowds with scalable behaviors. In: International Conference on Graphics, Patterns and Images. pp. 31–38 (2013)
- [22] Favaretto, R., Dihl, L., Barreto, R., Musse, S.R.: Using group behaviors to detect hofstede cultural dimensions. In: IEEE International Conference on Image Processing (ICIP) (2016)
- [23] Fruin, J.: Pedestrian Planning and Design. Metropolitan Association of Urban Designers and Environmental Planners (1971)
- [24] Golas, A., Narain, R., Lin, M.: Hybrid long-range collision avoidance for crowd simulation. In: International Conference Symposium on Interactive 3D Graphics and Games (SIGGRAPH). pp. 29–36. ACM, New York, NY, USA (2013)

- [25] Guy, S.J., Chhugani, J., Curtis, S., Dubey, P., Lin, M., Manocha, D.: Pledestrians: a least-effort approach to crowd simulation. In: International Conference Eurographics Symposium on Computer Animation, SIGGRAPH. pp. 119–128. SCA '10, Eurographics Association, Aire-la-Ville, Switzerland, Switzerland (2010)
- [26] Guy, S.J., Chhugani, J., Kim, C., Satish, N., Lin, M.C., Manocha, D., Dubey, P.: Clearpath: Highly parallel collision avoidance for multi-agent simulation. In: International Conference Eurographics Symposium on Computer Animation, SIGGRAPH. pp. 177–187. ACM (2009)
- [27] Hakiri, A., Berthou, P., Gayraud, T.: Qos-enabled anfis dead reckoning algorithm for distributed interactive simulation. In: International Conference Computer Society. pp. 33–42 (2010)
- [28] Hall, E.: Toward an understanding of flow in video games. *American Anthropologist* (65), 1003–1026 (1963)
- [29] Hardy, A., Venter, J.: 3vieww impostors. In: International Conference on Computer Graphics, Virtual Reality, Visualisation and Interaction in Africa. pp. 129–138. AFRI-GRAPH '10, ACM (2010)
- [30] Haworth, B., Usman, M., Berseth, G., Kapadia, M., Faloutsos, P.: Evaluating and optimizing level of service for crowd evacuations. In: International Conference on Motion in Games. pp. 91–96. MIG '15, ACM, New York, NY, USA (2015)
- [31] Helbing, D., Molnar, P.: Self-organized pedestrian crowd dynamics. *Transportation Science* 39(1), 1–24 (Mar 1998)
- [32] Henry, J., Shum, H.P.H., Komura, T.: Interactive formation control in complex environments. *IEEE Transactions on Visualization and Computer Graphics* 20(2), 211–222 (Feb 2014)
- [33] Hoff, III, K.E., Keyser, J., Lin, M., Manocha, D., Culver, T.: Fast computation of generalized voronoi diagrams using graphics hardware. In: International Conference on Computer Graphics and Interactive Techniques. SIGGRAPH, New York, NY, USA (1999)
- [34] Huang, P., Kang, J., Kider, J.T., Sunshine-Hill, B., McCaffrey, J.B., Rios, D.V., Badler, N.I.: Real-Time Evacuation Simulation in Mine Interior Model of Smoke and Action. *Annual Conference on Computer Animation and Social Agents* (Feb 2010)
- [35] Jiang, H., Xu, W., Mao, T., Li, C., Xia, S., Wang, Z.: Continuum crowd simulation in complex environments. *Computers Graphics* 34(5), 537–544 (2010)
- [36] Jin, Y., Toh, H.S., Soh, W.S., Wong, W.C.: A robust dead-reckoning pedestrian tracking system with low cost sensors. In: International Conference Pervasive Computing and Communications (PerCom). pp. 222–230 (Mar 2011)

- [37] Kallmann, M.: Shortest paths with arbitrary clearance from navigation meshes. In: International Conference on Computer Animation (SCA) (2010)
- [38] Kapadia, M., Beacco, A., Garcia, F., Reddy, V., Pelechano, N., Badler, N.I.: Multi-domain real-time planning in dynamic environments. In: Conference International on Computer Animation, SIGGRAPH/Eurographics. pp. 115–124. SCA '13, ACM, New York, NY, USA (2013)
- [39] Kapadia, M., Shoulson, A., Durupinar, F., Badler, N.I.: *Authoring Multi-actor Behaviors in Crowds with Diverse Personalities*. Springer New York (2013)
- [40] Kapadia, M., Wang, M., Singh, S., Reinman, G., Faloutsos, P.: Scenario space: Characterizing coverage, quality, and failure of steering algorithms. In: International Conference on Computer Animation, SIGGRAPH/Eurographics. pp. 53–62. SCA '11 (2011)
- [41] Kaur, S., Rani, J.: Increasing efficiency of crowd simulation using particle swarm optimization. *Journal of Innovative Research in Computer and Communication Engineering* 12(3), 217–225 (2013)
- [42] L. Hughes, R.: *The Flow of Human Crowds*, vol. 35 (Jan 2003)
- [43] Ladetto, Q., Merminod, B.: Digital magnetic compass and gyroscope integration for pedestrian navigation. In: 9th International Conference on Integrated Navigation Systems, St-Petersburg. pp. 27–29 (2002)
- [44] Ladetto, Q., Seeters, J.V., Sokolowski, S., Sagan, Z., Merminod, B.: Digital magnetic compass and gyroscope for dismounted soldier position and navigation. In: Symposium on Emerging Military Capabilities Enabled by Advances in Navigation Sensors (2002)
- [45] Lai, C.D., N. Pra Murthy, D., Xie, M.: Weibull distributions and their applications Chapter 3, 63–78 (Feb 2006)
- [46] LeBon, G.: *Psychologie des Foules*. Alcan, Paris, [1st ed.] edn. (1985)
- [47] Lemerrier, S., Auberlet, J.M.: Towards more behaviours in crowd simulation. *Computer Animation and Virtual Worlds* 27(1), 24–34 (2016)
- [48] Likhachev, M., Gordon, G., Thrun, S.: ARA\*: Anytime A\* search with provable bounds on sub-optimality. In: Thrun, S., Saul, L., Schölkopf, B. (eds.) International Conference on Neural Information Processing Systems (NIPS). MIT Press (2003)
- [49] Likhachev, M., Ferguson, D., Gordon, G., Stentz, A., Thrun, S.: Anytime search in dynamic graphs. *Artificial Intelligence* 172(14), 1613 – 1643 (2008)

- [50] Martinelli, A., Gao, H., Groves, P.D., Morosi, S.: Probabilistic context-aware step length estimation for pedestrian dead reckoning. *IEEE Sensors Journal* 18(4), 1600–1611 (Feb 2018)
- [51] Moore, S., Flajslik, M., Rosin, P., Marshall, D.: A particle model of crowd behavior: Exploring the relationship between alcohol, crowd dynamics and violence 13, 413–422 (Nov 2008)
- [52] Moussaïd, M., Helbing, D., Theraulaz, G.: How simple rules determine pedestrian behavior and crowd disasters. *Proceedings of the National Academy of Sciences* 108(17), 6884–6888 (2011)
- [53] Musse, S., Jung, C., Jacques, J.C.S., Braun, A.: Using computer vision to simulate the motion of virtual agents: Research articles. *Computer Animation Virtual Worlds* 18(2), 83–93 (May 2007)
- [54] Musse, S.R., Thalmann, D.: Hierarchical model for real time simulation of virtual human crowds. *IEEE Transactions on Visualization and Computer Graphics* 7(2), 152–164 (2001)
- [55] Musse, S., Thalmann, D.: A model of human crowd behavior : Group inter-relationship and collision detection analysis. In: *Computer Animation and Simulation '97*. Eurographics (1997)
- [56] Narain, R., Golas, A., Curtis, S., Lin, M.C.: Aggregate dynamics for dense crowd simulation. In: *ACM SIGGRAPH Asia 2009 Papers*. pp. 122:1–122:8 (2009)
- [57] Oliveira, J.B.S.: Two algorithms for automatic document page layout. In: *Proceedings of the eighth ACM symposium on Document engineering*. pp. 141–149. ACM, New York, NY, USA (2008)
- [58] Pan, X., Han, C.S., Dauber, K., Law, K.H.: A multi-agent based framework for the simulation of human and social behaviors during emergency evacuations. *AI & Society* 22(2), 113–132 (Feb 2007)
- [59] Paris, S., Gerdelan, A., O’Sullivan, C.: CA-LOD: collision avoidance level of detail for scalable, controllable crowds. In: *Motion in Games, Second International Workshop, MIG, 2009*
- [60] Paris, S., Pettré, J., Donikian, S.: Pedestrian reactive navigation for crowd simulation: a predictive approach. *Computer Graphics Forum* 26(3), 665–674 (Mar 2007)
- [61] Park, S.I., Quek, F., Cao, Y.: Simulating and animating social dynamics: embedding small pedestrian groups in crowds. *Computer Animation and Virtual Worlds* 24(3-4), 155–164 (2013)

- [62] Pauwels, P., Krijnen, T., Terkaj, W., Beetz, J.: Enhancing the ifcowl ontology with an alternative representation for geometric data. *Automation in Construction* 80, 77 – 94 (2017)
- [63] Pelechano, N., Allbeck, J.M., Badler, N.I.: Virtual crowds: Methods, simulation, and control. *Synthesis Lectures on Computer Graphics and Animation* 3(1), 1–176 (2008)
- [64] Perkins, L.: Terrain analysis in real-time strategy games: An integrated approach to choke point detection and region decomposition. (Jan 2010)
- [65] Pettre, J., Ciechomski, P.d.H., Maim, J., Yersin, B., Laumond, J.P., Thalmann, D.: Real-time navigating crowds: scalable simulation and rendering. *Computer Animation and Virtual Worlds* 17(3-4), 445–455 (Nov 2006)
- [66] Pettré, J., Ondrej, J., Olivier, A.H., Crétual, A., Donikian, S.: Experiment-based modeling, simulation and validation of interactions between virtual walkers. In: Symposium on Computer Animation. pp. 189–198. ACM (2009)
- [67] Randell, C., Djallis, C., Muller, H.: Personal position measurement using dead reckoning. In: In Proceedings of The Seventh International Symposium on Wearable Computers. pp. 166–173. Springer (2003)
- [68] Reynolds, C.W.: Flocks, herds and schools: A distributed behavioral model. In: Proceedings of the 14th Annual Conference on Computer Graphics and Interactive Techniques. pp. 25–34. SIGGRAPH '87 (1987)
- [69] Runions, A., Lane, B., Prusinkiewicz, P.: Modeling trees with a space colonization algorithm. In: Proceedings of the Third Eurographics Conference on Natural Phenomena. pp. 63–70 (2007)
- [70] Sewall, J., van den Berg, J., Lin, M., Manocha, D.: Virtualized traffic: Reconstructing traffic flows from discrete spatiotemporal data. *IEEE transactions on visualization and computer graphics*. 17, 26–37 (Jan 2011)
- [71] Shi, W., Corriveau, J.P., Agar, J.: Dead reckoning using play patterns in a simple 2d multiplayer online game. *International Journal of Computer Games Technology* 2, 5:5–5:5 (Jan 2014)
- [72] Shin, S.H., Lee, M.S., Park, C.G., Hong, H.S.: Pedestrian dead reckoning system with phone location awareness algorithm. In: Position Location and Navigation Symposium (PLANS), 2010 IEEE/ION. pp. 97–101 (May 2010)
- [73] Still, G.K.: Crowd Dynamics. Ph.D. thesis, University of Warwick, Coventry, UK (2000)

- [74] Stu, X., Terzopoulos, D.: Artificial fishes: physics, locomotion, perception, behavior. *Conference on Computer Graphics and Interactive Techniques (SIGGRAPH)* p. 43–50 (1994)
- [75] Sun, L., Li, X., Qin, W.: Simulating realistic crowd based on agent trajectories. *Computer Animation and Virtual Worlds* 24(3-4), 165–172 (May 2013)
- [76] Thalmann, D., Musse, R.S.: *Crowd Simulation*. Springer–Verlag, London (2013)
- [77] Thalmann, D.: Populating virtual environments with crowds. In: *Proceedings of the 2006 ACM International Conference on Virtual Reality Continuum and Its Applications*. pp. 11–11 (2006)
- [78] Turner, J.C.: *Rediscovering the Social Group: A Self-categorization Theory*. Blackwell Publishers (1987)
- [79] Ulicny, B., Thalmann, D.: Crowd simulation for interactive virtual environments and VR training systems, pp. 163–170 (2001)
- [80] Van Den Berg, J., Patil, S., Sewall, J., Manocha, D., Lin, M.: Interactive navigation of multiple agents in crowded environments. In: *Proceedings of the 2008 Symposium on Interactive 3D Graphics and Games*. pp. 139–147 (2008)
- [81] Warren, C.W.: Multiple robot path coordination using artificial potential fields. In: *Proceedings., IEEE International Conference on Robotics and Automation*. pp. 500–505 vol.1 (May 1990)
- [82] Xu, M.L., Jiang, H., Jin, X.G., Deng, Z.: Crowd simulation and its applications: Recent advances. *Journal of Computer Science and Technology* 29(5), 799–811 (2014)
- [83] Yahyavi, A., Huguenin, K., Kemme, B.: Interest Modeling in Games: The Case of Dead Reckoning. *Multimedia Systems* 19(3), 255–270 (Jun 2013)
- [84] Yoon, S., Kapadia, M., Sahu, P., Pavlovic, V.: Filling in the blanks: reconstructing microscopic crowd motion from multiple disparate noisy sensors. In: *IEEE Winter Applications of Computer Vision Workshops (WACVW)*. pp. 1–9 (March 2016)



Pontifícia Universidade Católica do Rio Grande do Sul  
Pró-Reitoria de Graduação  
Av. Ipiranga, 6681 - Prédio 1 - 3º. andar  
Porto Alegre - RS - Brasil  
Fone: (51) 3320-3500 - Fax: (51) 3339-1564  
E-mail: [prograd@pucrs.br](mailto:prograd@pucrs.br)  
Site: [www.pucrs.br](http://www.pucrs.br)