

Universidade Federal de Minas Gerais  
Instituto de Ciências Exatas  
Programa de Pós-Graduação em Estatística

Ana Gabriela Braga

*Modelagem Espaço-Temporal de Processos Pontuais:  
Aplicação em circuitos de televisão para controle de crimes*

Orientador: Prof. Dr. Marcos Oliveira Prates

Co-orientador: Prof. Dr. Alexandre Loureiros Rodrigues

Belo Horizonte

2016

UNIVERSIDADE FEDERAL DE MINAS GERAIS  
INSTITUTO DE CIÊNCIAS EXATAS  
CURSO DE PÓS-GRADUAÇÃO EM ESTATÍSTICA

Ana Gabriela Braga

*Modelagem Espaço-Temporal de Processos Pontuais:  
Aplicação em circuitos de televisão para controle de crimes*

Belo Horizonte  
2016

Ana Gabriela Braga

*Modelagem Espaço-Temporal de Processos Pontuais:  
Aplicação em circuitos de televisão para controle de crimes*

Dissertação apresentada ao Curso de Estatística da UFMG, como requisito para a obtenção do grau de MESTRE em Estatística.

**Orientador: Marcos Oliveira Prates**

**Doutor em Estatística**

**Co-orientador: Alexandre Loureiros Rodrigues**

**Doutor em Estatística**

Belo Horizonte

2016

Braga, Ana Gabriela

Modelagem Espaço-Temporal de Processos Pontuais: Aplicação em  
circuitos de televisão para controle de crimes / Ana Gabriela Braga  
- 2016

87.p

1.Estatística. I.Título.

CDU 519.5

Ana Gabriela Braga

*Modelagem Espaço-Temporal de Processos Pontuais:  
Aplicação em circuitos de televisão para controle de crimes*

Dissertação apresentada ao Curso de Estatística da UFMG, como requisito para a obtenção do grau de MESTRE em Estatística.

Aprovado em 25 de fevereiro de 2016

**BANCA EXAMINADORA**

---

Marcos Oliveira Prates

Doutor em Estatística

---

Thais Cristina Oliveira da Fonseca

Doutora em Estatística

---

Renato Martins Assunção

Doutor em Estatística

*Aos meus pais, Rodrigo, Carol e Theo.*

## Resumo

O aumento da população ao longo dos séculos tem provocado importantes impactos em diversos fatores pertencentes ao cotidiano da sociedade, sendo a criminalidade o principal deles. Portanto, para as autoridades, monitorar os crimes é imprescindível para a criação de políticas públicas de controle dessas infrações. Por esse motivo, o mapeamento de crimes se faz necessário para detectar mudanças no padrão espacial e temporal de ocorrência desses eventos. A necessidade de apresentar soluções estratégicas que interrompam e revertam de forma significativa tais fatores, ocasionou o desenvolvimento de métodos estatísticos para a análise de processos desta natureza, principalmente, devido à grande aplicabilidade dos modelos espaço-temporais.

Neste trabalho, propomos uma metodologia espaço-temporal para processos pontuais, com o objetivo de mapear a degradação temporal do efeito da instalação de 60 câmeras de circuito fechado de televisão (CCTV) na distribuição de crimes contra a pessoa, em uma região de alta criminalidade da cidade de Belo Horizonte.

A inferência desse modelo é feita sob a abordagem Bayesiana, com utilização de métodos MCMC, mais precisamente o amostrador de *Gibbs* com passos de *Metropolis-Hastings*.

Palavras-chaves: Processos pontuais espaço-temporais, criminalidade, inferência bayesiana, MCMC.

## Abstract

The increase in population over the centuries has led to significant impacts on various factors belonging to the everyday life of society, criminality is the principal among them. Therefore, for the authorities, to monitor crimes is indispensable for the creation of public politics to control these infractions. For this reason, the mapping of crimes is necessary to detect changes on the spatio temporal pattern of the occurrence of these events. The need to introduce strategic solutions that interrupt and revert such factors in a significant way caused the development of statistical methods to the analysis of process of this nature, mainly due to the vast applicability of the spatio temporal models.

In this work, we propose a spatio temporal methodology to point process, which purpose is to map the temporal degradation of the effect of the installation of 60 cameras of Closed Circuit Television (CCTV) on the distribution of crimes against a person, in a region with high criminality of the city Belo Horizonte.

This model's inference is done under the Bayesian approach utilizing MCMC methods, more precisely, the Gibbs sampler with Metropolis-Hastings steps.

Keywords: Spatio-temporal point process, criminality, Bayesian inference, MCMC.

## Agradecimentos

Primeiramente agradeço a Deus por iluminar meu caminho e me dar forças, mostrando sempre que tudo é possível.

Ao meu Orientador Marcos Prates, pela confiança, pela oportunidade de trabalhar ao seu lado e por exercer da melhor forma seu papel de orientador. Agradeço seus ensinamentos e sua dedicação, para que esse trabalho fosse executado da melhor forma possível. Muito Obrigada!

Aos meus pais, por sempre acreditarem em mim e mostrar que sempre sou capaz. Pelo apoio imenso durante essa caminhada e durante toda minha vida, priorizando sempre meus estudos. À minha irmã Carol, com seus conselhos valiosos e por ser referência para mim, na vida e estudos. Ao Theo, que através de seu nascimento, fez pairar sobre todos nós a felicidade e fez o amor reinar e transbordar em nossa família. Amo vocês!

Ao meu amor Rodrigo, que com sua paz, serenidade, amor e carinho entendeu cada minuto da minha ausência. Obrigada por todos os ensinamentos e conselhos. Por acreditar em mim, ser o meu suporte e a minha paz e sempre mostrar que a tranquilidade é a guia mestre de todos os momentos. Pelos puxões de orelhas nos momentos certos, pelas risadas, pelas viagens e passatempos. Sem você seria impossível. Meu agradecimento mais que especial a você! Te amo infinitamente.

As minhas amigas, que já são e serão parte indissociável da minha vida: Bárbara, Juliana e Fernanda. Obrigada por compartilharem todos os momentos, tristes e/ou alegres. Por fazerem de momentos simples, únicos e por transformar tudo nas melhores risadas do planeta. Com vocês foi mais fácil. Obrigada pelos conselhos, pelas fofocas, pela sinceridade, pela fidelidade e, principalmente, por se dedicarem à nossa amizade. Que continuemos unidas, mesmo seguindo por caminhos diferentes. Amo vocês!

Ao Bráulio pelo aprendizado, por ser tão prestativo, pela paciência e pelas valiosas explicações. Ao Douglas, por tudo, principalmente pela amizade e infinitos ensinamentos. Ao Estevão por sua racionalidade e por toda a ajuda durante o curso. Muito Obrigada a vocês!

Às meninas do LESTE, Zaida, Juliane e Livia, por fazer parte dessa caminhada, por toda a ajuda e conselhos.

À Rogéria e Rose, por organizarem e fazerem nossa vida ser mais fácil durante essa jornada. Meninas, sem a ajuda e o trabalho de vocês seria impossível. Muito Obrigada! Que Deus continue abençoando vocês! À Maísa pelo imprescindível café de cada dia!

Enfim, agradeço a todos que de alguma forma contribuíram para alcançar essa vitória. Muito Obrigada!

# Sumário

<b>Lista de Figuras</b>	<b>8</b>
<b>Lista de Tabelas</b>	<b>12</b>
<b>1 Introdução</b>	<b>13</b>
1.1 Motivação . . . . .	14
1.2 Objetivos . . . . .	16
1.3 Organização do trabalho . . . . .	17
<b>2 Conceitos e Definições Gerais</b>	<b>18</b>
2.1 Processos Pontuais Espaço-Temporais . . . . .	18
2.2 Sistemas de Circuito Fechado de Televisão e Criminalidade . . . . .	19
2.3 Inferência Bayesiana . . . . .	21
2.3.1 Teorema de Bayes . . . . .	21
2.3.2 Distribuições <i>a priori</i> . . . . .	22
2.3.3 Distribuição <i>a posteriori</i> . . . . .	23
2.3.4 Técnicas de Monte Carlo via Cadeias de Markov . . . . .	23
2.4 Recursos Computacionais . . . . .	25
<b>3 Materiais e Métodos</b>	<b>28</b>
3.1 Descrição dos Dados . . . . .	28
3.2 Formulação do Modelo . . . . .	33
3.2.1 Metodologia Inicial . . . . .	33
3.2.2 Extensão da Metodologia . . . . .	34
3.3 Modelagem Bayesiana . . . . .	39

3.3.1	Função de Verossimilhança . . . . .	39
3.3.2	Distribuições <i>a priori</i> . . . . .	40
3.3.3	Distribuição <i>a priori</i> conjunta . . . . .	41
3.3.4	Distribuição <i>a posteriori</i> . . . . .	41
3.3.5	Condicionais Completas . . . . .	42
<b>4</b>	<b>Aplicação</b>	<b>43</b>
4.1	Estudo 1: Aplicação do modelo a todas as 60 câmeras. . . . .	43
4.2	Estudo 2: Aplicação do modelo a grupos de câmeras. . . . .	48
4.2.1	Análise das estimativas obtidas pelos dados do Grupo 01 . . . . .	49
4.2.2	Análise das estimativas obtidas pelos dados do Grupo 04 . . . . .	52
4.3	Estudo 3: Aplicação do modelo a cada câmera individualmente. . . . .	55
<b>5</b>	<b>Considerações Finais e Trabalhos Futuros</b>	<b>59</b>
5.1	Considerações Finais . . . . .	59
5.2	Trabalhos Futuros . . . . .	60
<b>A</b>	<b>Apêndice</b>	<b>61</b>
<b>B</b>	<b>Apêndice</b>	<b>63</b>
<b>C</b>	<b>Apêndice</b>	<b>66</b>
<b>D</b>	<b>Apêndice</b>	<b>68</b>
D.0.1	Análise das estimativas obtidas pelos dados do Grupo 02 . . . . .	68
D.0.2	Análise das estimativas obtidas pelos dados do Grupo 03 . . . . .	70
D.0.3	Análise das estimativas obtidas pelos dados do Grupo 05 . . . . .	72
D.0.4	Análise das estimativas obtidas pelos dados do Grupo 06 . . . . .	75
<b>E</b>	<b>Apêndice</b>	<b>78</b>

## Lista de Figuras

1.1	Mapa elaborado por John Snow. Os casos de cólera são representadas por pontos e bombas de abastecimento de água identificadas com x. . . . .	15
3.1	Mapa do município de Belo Horizonte, em destaque o bairro Centro. . . . .	28
3.2	Distribuição dos crimes contra pessoa no bairro Centro de Belo Horizonte. . . . .	29
3.3	Localização das câmeras no bairro Centro de Belo Horizonte. . . . .	29
3.4	Distribuição dos crimes na região em estudo: à esquerda crimes que ocorreram antes da instalação das câmeras; à direita crimes que ocorreram após a instalação das câmeras. . . . .	30
3.5	Numeração atribuída às câmeras instaladas no Centro de Belo Horizonte. . . . .	30
3.6	Razão entre a proporção de crimes que ocorreram depois e antes da intervenção, na vizinhança de cada câmera. O quadrado representa as razões menores que 1 e, o círculo, razões maiores que 1. . . . .	31
3.7	Número de crimes, por mês, após a instalação das câmeras. . . . .	32
3.8	Percentual de crimes, por hora do dia, que ocorreram antes e após a instalação das câmeras. . . . .	33
3.9	Função $g(t)$ para diferentes combinações dos parâmetros $(\theta_1, \theta_2, \theta_3$ e $\theta_4)$ . . . . .	35
4.1	Estimativas de $f(x)$ (média <i>a posteriori</i> e intervalo de 95% credibilidade), para a Avenida Afonso Pena e Avenida Amazonas. . . . .	44
4.2	Estimativas de $f(x)$ (média <i>a posteriori</i> e intervalo de 95% credibilidade), para a Rua dos Tupinambás, Rua Curitiba, Rua dos Caetés e Rua dos Guaranis. . . . .	45
4.3	Estimativa <i>a posteriori</i> da função $g(t)$ para as 60 câmeras. . . . .	45
4.4	Estimativa <i>a posteriori</i> da função $g(t)$ para as 60 câmeras. . . . .	46

4.5	Mapas da distribuição dos crimes em seis períodos de tempo, após a instalação das câmeras. . . . .	46
4.6	Estimativas de $h(x, t)$ , para a Avenida Afonso Pena e Avenida Amazonas, nos tempos $t = 3, 8, 13$ e $15$ meses. . . . .	47
4.7	Estimativas de $h(x, t)$ , para a Rua dos Tupinambás, Rua Curitiba, Rua dos Caetés e Rua dos Guaranis, nos tempos $t = 3, 8, 13$ e $15$ meses. . . . .	48
4.8	Distribuição das câmeras de circuito fechado de televisão, por grupo. . . .	49
4.9	Número de crimes, por mês, após a instalação das câmeras para o grupo 01.	50
4.10	Estimativas de $f(x)$ (média <i>a posteriori</i> e intervalo de 95% credibilidade) para a Rua Curitiba e Rua dos Caetés, para o grupo 01. . . . .	51
4.11	Estimativa <i>a posteriori</i> da função $g(t)$ , para o grupo 01 das câmeras. . . .	51
4.12	Estimativas de $h(x, t)$ para a Rua Curitiba e Rua dos Caetés, para o grupo 01, nos tempos $t = 1, 2, 3$ e $6$ meses. . . . .	52
4.13	Número de crimes, por mês, após a instalação das câmeras, para o grupo 04.	52
4.14	Estimativas de $f(x)$ (média <i>a posteriori</i> e intervalo de 95% credibilidade) para a Avenida Afonso Pena, Avenida Amazonas, Rua dos Tupinambás e Rua dos Carijós, para o grupo 04. . . . .	53
4.15	Estimativa <i>a posteriori</i> da função $g(t)$ , para o grupo 04 das câmeras. . . .	54
4.16	Estimativas de $h(x, t)$ para a Avenida Afonso Pena, Avenida Amazonas, Rua dos Tupinambás e Rua dos Carijós, para o grupo 04, nos tempos $t = 5, 17, 19$ e $24$ meses. . . . .	55
4.17	Estimativa <i>a posteriori</i> da função $g(t)$ para as câmeras 3 e 59. . . . .	57
4.18	Estimativa <i>a posteriori</i> da função $g(t)$ para as câmeras 15 e 17. . . . .	57
4.19	Estimativa <i>a posteriori</i> da função $g(t)$ para as câmeras 34 e 44. . . . .	58
C.1	Estimativas de $f(x)$ (média <i>a posteriori</i> e intervalo de 90% credibilidade), para a Rua dos Carijós, Rua Espírito Santo, Rua Rio de Janeiro, Rua São Paulo, Rua dos Tamoios, Rua da Bahia, Rua Bias Fortes, Rua dos Goitacazes, Rua Guaicurus, Rua Oiapoque, Avenida Olegário Maciel, Rua Paraná, Rua Santos Dumont e Rua dos Tupis. . . . .	67

D.1	Número de crimes, por mês, após a instalação das câmeras, para o grupo 02.	68
D.2	Estimativas de $f(x)$ (média <i>a posteriori</i> e intervalo de 95% credibilidade) para a Rua Guaicurus e Rua Santos Dumont, para o grupo 02. . . . .	69
D.3	Estimativa <i>a posteriori</i> da função $g(t)$ , para o grupo 02 das câmeras. . . .	69
D.4	Estimativas de $h(x, t)$ para a Rua Guaicurus e Rua dos Santos Dumont, para o grupo 02, nos tempos $t = 3, 10, 13$ e $15$ meses. . . . .	70
D.5	Número de crimes, por mês, após a instalação das câmeras, para o grupo 03.	71
D.6	Estimativas de $f(x)$ (média <i>a posteriori</i> e intervalo de 95% credibilidade) para a Rua dos Tupinambás e Avenida Olegário Maciel, para o grupo 03. .	71
D.7	Estimativa <i>a posteriori</i> da função $g(t)$ , para o grupo 03 das câmeras. . . .	72
D.8	Estimativas de $h(x, t)$ para a Rua Tupinambás e Avenida Olegário Maciel, para o grupo 03, nos tempos $t = 1, 4, 8$ e $12$ meses. . . . .	72
D.9	Número de crimes, por mês, após a instalação das câmeras, para o grupo 05.	73
D.10	Estimativas de $f(x)$ (média <i>a posteriori</i> e intervalo de 95% credibilidade) para a Avenida Amazonas e Avenida Augusto de Lima, para o grupo 05. .	74
D.11	Estimativa <i>a posteriori</i> da função $g(t)$ , para o grupo 05 das câmeras. . . .	74
D.12	Estimativas de $h(x, t)$ para a Avenida Amazonas e Avenida Augusto de Lima, para o grupo 05, nos tempos $t = 5, 12, 15$ e $18$ meses. . . . .	75
D.13	Número de crimes, por mês, após a instalação das câmeras, para o grupo 06.	75
D.14	Estimativas de $f(x)$ (média <i>a posteriori</i> e intervalo de 95% credibilidade) para a Avenida Augusto de Lima e Rua dos Goitacazes, para o grupo 06. .	76
D.15	Estimativa <i>a posteriori</i> da função $g(t)$ , para o grupo 06 das câmeras. . . .	77
D.16	Estimativas de $h(x, t)$ para a Avenida Augusto de Lima e Rua dos Goitacazes, para o grupo 06, nos tempos $t = 3, 8, 13$ e $15$ meses. . . . .	77
E.1	Estimativa <i>a posteriori</i> da função $g(t)$ para as câmeras 1, 2, 4, 5, 6, 7, 8 e 9.	78
E.2	Estimativa <i>a posteriori</i> da função $g(t)$ para as câmeras 10, 11, 12, 13, 14, 16, 18 e 19. . . . .	79

E.3	Estimativa <i>a posteriori</i> da função $g(t)$ para as câmeras 20, 21, 22, 23, 24, 25, 26 e 27. . . . .	80
E.4	Estimativa <i>a posteriori</i> da função $g(t)$ para as câmeras 28, 29, 30, 31, 32, 33, 35 e 36. . . . .	81
E.5	Estimativa <i>a posteriori</i> da função $g(t)$ para as câmeras 37, 38, 39, 40, 41, 42, 43 e 45. . . . .	82
E.6	Estimativa <i>a posteriori</i> da função $g(t)$ para as câmeras 46, 47, 48, 49, 50, 51, 52 e 53. . . . .	83
E.7	Estimativa <i>a posteriori</i> da função $g(t)$ para as câmeras 54, 55, 56, 57, 58 e 60. . . . .	84

## Lista de Tabelas

2.1	Tempo (em segundos) de execução da multiplicação de duas matrizes em R, Rcpp (C++) e C. . . . .	27
3.1	Distribuição da quantidade total de crimes, após a instalação das câmeras, em intervalos de meses. . . . .	32
4.1	Distribuição da quantidade de crimes do grupo 01, após a instalação das câmeras, em intervalos de meses. . . . .	50
4.2	Distribuição da quantidade de crimes do grupo 04, após a instalação das câmeras, em intervalos de meses. . . . .	53
D.1	Distribuição da quantidade de crimes do grupo 02, após a instalação das câmeras, em intervalos de meses. . . . .	69
D.2	Distribuição da quantidade de crimes do grupo 03, após a instalação das câmeras, em intervalos de meses. . . . .	71
D.3	Distribuição da quantidade de crimes do grupo 05, após a instalação das câmeras, em intervalos de meses. . . . .	73
D.4	Distribuição da quantidade de crimes do grupo 06, após a instalação das câmeras, em intervalos de meses. . . . .	76

# 1 Introdução

Compreender a distribuição dos dados resultantes de fenômenos ocorridos no espaço é de interesse para a resolução de questões centrais em várias áreas do conhecimento, seja em saúde, ecologia, criminologia, dentre tantas outras.

A dependência espacial entre as observações, na análise de fenômenos espaciais, é de suma importância dentre os diversos fatores que podem ser estudados. Para realizar inferência, os dados espaciais são considerados como uma realização de um processo estocástico, onde todas as observações são consideradas conjuntamente para descrever o padrão espacial do fenômeno estudado.

Os padrões espaciais são frequentemente classificados em três grupos:

- *Eventos ou Padrões Pontuais*: fenômenos expressos como pontos localizados aleatoriamente no espaço, denominados processos pontuais.
- *Superfícies Contínuas*: estimadas com base em um conjunto de amostras de campo que podem estar regularmente ou irregularmente distribuídas. Usualmente, esse tipo de estrutura é resultante do levantamento de recursos naturais e inclui mapas geológicos, topográficos e ecológicos.
- *Áreas de Contagens e Taxas Agregadas*: tratam-se, em geral, de dados relacionados a levantamentos populacionais, como censos e estatísticas de saúde e que originalmente referem-se a indivíduos localizados em pontos específicos no espaço.

Naturalmente, com surgimento de novas estruturas de dados e evolução das existentes, métodos de análise estatística aplicados ao estudo de eventos espaciais evoluíram ao longo dos anos e modelos espaciais foram aprimorados. Grande destaque pode ser atribuído àqueles que incorporam, além da localização, o tempo, permitindo testar a existência de aglomerados no espaço e no tempo conjuntamente, ou seja, é possível verificar se os dados exibem interação espaço-tempo. Muitos estudos buscam variações espaciais que interferem na distribuição geográfica da ocorrência de um agravo, outros analisam aglomerados temporais, assim como existem estudos que investigam o crescimento ou decréscimo da taxa de ocorrência de eventos ao longo do tempo.

Muitos estudos aplicados registram ocorrências de eventos no espaço e no tempo. Na análise de crimes, por exemplo, registram-se delitos por hora e data de ocorrência e a área em que eles ocorreram dentro de uma determinada região. Na área de saúde, pode-se observar o dia de eclosão e a área geográfica de novos casos de uma determinada doença. Em Ecologia existe o interesse no padrão espacial de espécies de fauna e flora, e também em como essas espécies se organizam geograficamente e ao longo do tempo. Em Astronomia o interesse está na distribuição espacial de estrelas e galáxias, bem como na questão de onde e quando esses padrões espaciais mudam com o tempo, dentre outros exemplos (Simões (2006)).

Na última década, métodos espaço-temporais se tornaram objeto de investigação de vários pesquisadores. Em Rodrigues and Diggle (2012) um método é proposto para uma classe de processos pontuais espaço-temporais não estacionários, enquanto Moller and Díaz-Avalos (2010) discutem análise exploratória, estimação e predição em modelos espaço-temporais. Para mais trabalhos sobre métodos espaço-temporais ver, por exemplo, Diggle and Rodrigues (2010), Harvill (2010), Diggle et al. (2005) e Christakos (2000).

## 1.1 Motivação

O aumento da população ao longo dos séculos tem provocado importantes alterações e consequentes impactos em diversos fatores pertencente ao cotidiano da sociedade. Como exemplo, podemos citar questões de saúde, ambientais, econômicas, sociais, dentre outras.

A crescente necessidade de apresentar soluções estratégicas que interrompam e revertam de forma significativa tais fatores vem se fortalecendo cada vez mais. Visando obter soluções para tais problemas, ao longo dos anos, muitos estudiosos vêm propondo técnicas estatísticas que conduzam a tomadas de decisão para tal finalidade. Uma dessas técnicas é a modelagem espacial, que permite a compreensão da distribuição dos dados advindos de fenômenos ocorridos em certa região geográfica, o que é de grande utilidade para a solução de importantes questões nas mais diversas áreas do conhecimento.

Uma das primeiras aplicações da análise espacial aconteceu no ano de 1854 em Londres, Inglaterra, em um estudo realizado pelo médico John Snow. Naquela época a cidade estava sofrendo com um surto de cólera, e John acreditava que esse surto estava

relacionado à água que abastecia a cidade. Dessa forma, ele indicou em um mapa da cidade a localização dos casos de cólera e as bombas de abastecimento de água. Ficou evidente que a maioria dos casos registrados estavam situados em torno de uma determinada bomba localizada na Broad Street, como mostra a Figura 1.1. Com o auxílio de técnicas estatísticas e com estudos mais avançados John Snow conseguiu encontrar os meios de transmissão da cólera. Essa é uma situação comum em que a relação espacial entre os dados contribuiu significativamente para o avanço da compreensão do fenômeno.



Figura 1.1: Mapa elaborado por John Snow. Os casos de cólera são representadas por pontos e bombas de abastecimento de água identificadas com x.

Outros estudos que utilizaram a modelagem espacial podem ser citados: Menezes et al. (2008) estudaram a distribuição espacial e temporal da raiva bovina, em Minas Gerais, de 1998 a 2006. Já Taquette et al. (2011) analisaram a epidemia de AIDS em adolescentes no município do Rio de Janeiro para subsidiar políticas públicas de prevenção. Enquanto Silva (2015) analisou as características espaciais e temporais dos roubos de veículos ocorridos nas regiões das áreas de segurança pública integradas no Rio de Janeiro.

Portanto, análise espacial ou espaço-temporal tem se tornado de extrema importância para o estudo de diversas anomalias socioeconômicas e ambientais. Investigar tais questões é relevante para apontar soluções aos problemas que afetam a qualidade de vida populacional.

## 1.2 Objetivos

O presente estudo tem como objetivo analisar um conjunto de dados de crimes que ocorreram na cidade de Belo Horizonte, localizada na região Sudeste do Brasil, entre 01 de janeiro de 2002 e 31 de dezembro de 2006. Esse conjunto de dados foi previamente analisado por Rodrigues et al. (2010) que compararam a distribuição espacial dos crimes antes e depois da instalação de 60 câmeras de circuito fechado de televisão (CCTV), em uma região de alta criminalidade da cidade, ignorando qualquer variação temporal.

Aqui, propõe-se uma extensão espaço-temporal do modelo proposto por Rodrigues et al. (2010) para investigar, se ocorrer, o efeito da instalação das câmeras na distribuição espacial dos crimes ao longo do tempo. Para isso as seguintes análises serão realizadas:

- Análise conjunta dos dados coletados em torno de todas as câmeras, visando verificar o comportamento do efeito global das câmeras;
- Construção de blocos com câmeras vizinhas no espaço, realizando o ajuste de uma função temporal para cada região. Busca-se identificar se a instalação das câmeras ocasionou o mesmo efeito em todo o espaço em estudo;
- Ajuste de uma função do tempo para cada câmera. Dessa forma, será possível verificar detalhadamente se o efeito da instalação das câmeras varia entre os locais de instalação das mesmas.

Como objetivo final deseja-se concluir se o efeito das câmeras será através da redução dos crimes ao longo do tempo, se os eventos foram deslocados para outras regiões ou até mesmo se efeito ocorre até determinado período e deteriora-se ao longo do tempo. Dessa forma, espera-se mostrar a eficácia, ou não, dessa política pública de controle de crimes empregada no bairro Centro da cidade de Belo Horizonte.

---

## 1.3 Organização do trabalho

Este texto é composto de mais quatro capítulos. O Capítulo 2 concentra os conceitos básicos para a escrita e desenvolvimento desse trabalho, como visão geral de processos pontuais espaço-temporais, a descrição da instalação dos sistemas de circuito fechado de televisão no Brasil e em outros países, além de caracterizar os processos de inferência Bayesiana que serão empregados em capítulo posterior.

A descrição dos dados, o estudo e apresentação do modelo proposto, além da descrição de toda a modelagem bayesiana empregada no trabalho, estão apresentados no Capítulo 3. Já a aplicação do modelo ao conjunto de dados de crimes que ocorreram na região central da cidade de Belo Horizonte são mostrados no Capítulo 4.

Finalmente, o Capítulo 5 resume as conclusões do trabalho e aponta caminhos para pesquisas futuras nesta importante área da Estatística.

## 2 Conceitos e Definições Gerais

### 2.1 Processos Pontuais Espaço-Temporais

Estudos em diversas áreas da ciência nos levam a dados na forma de uma coleção enumerável de pontos distribuídos de maneira aparentemente aleatória, em determinado conjunto. Frequentemente, os dados podem conter características desses eventos como a localização nas quais esses fenômenos ocorrem, e o tempo de ocorrência dos mesmos.

O tipo particular de processo utilizado para modelar esse tipo de evento é denominado processo pontual. Assim, pode-se definir um processo pontual como um modelo matemático utilizado para descrever um conjunto enumerável de pontos distribuídos aleatoriamente em algum espaço. Conseqüentemente, por possuir grande estrutura matemática, tais processos possuem inúmeras conexões com outras áreas de probabilidade e processos estocásticos.

Processos pontuais espaciais podem ser designados como fenômenos expressos por meio de ocorrências identificadas como pontos localizados no espaço. O conjunto das localizações espaciais observadas  $Z = x_1, x_2, \dots, x_n$  é chamado de arranjo pontual, e cada localização é usualmente chamada de evento.

Existem várias extensões para a estrutura básica de processos pontuais espaciais. Segundo Maia (2005), pode-se citar:

- *Processos pontuais marcados*: cada ponto associa-se a um conjunto de variáveis, sendo contínuas ou discretas. Como exemplo podemos citar os terremotos, nos quais a localização, data, magnitude e valor econômico dos danos de cada terremoto foi medido;
- *Processos Pontuais Multivariados*: os eventos são da forma  $(x_i, \delta_i)$  onde  $\delta_i$  registra o tipo do  $i$ -ésimo evento dentre dois os mais tipos qualitativamente diferentes. Um exemplo são as localizações de duas espécies de árvores, que estão localizadas em uma região onde se deseja estudar a relação espacial das duas espécies;

- *Processos pontuais espaço-temporais*: cada evento é da forma  $(x_i, t_i)$  onde  $t_i$  é o tempo de ocorrência relacionado ao  $i$ -ésimo evento. Exemplos incluem dados epidemiológicos, onde a localização e data do início de cada caso de uma particular doença foi registrado, ou dados de crime, onde a localização e data de ocorrência de cada crime foi registrado.

A proposta dessa dissertação é trabalhar com a última extensão.

## 2.2 Sistemas de Circuito Fechado de Televisão e Criminalidade

Desde meados da década de 1970, a violência urbana se destaca dentre as principais preocupações diárias da sociedade brasileira. É fato notório a ampla cobertura dos eventos que concernem ao ambiente do crime no país realizada pelos veículos de comunicação nacionais – e, não raramente, internacionais – o que expande ainda mais o sentimento de insegurança instalado na ampla maioria dos municípios brasileiros, bem como a visão geral dos residentes em outros países de que o termo “violência” é parte indissociável da realidade brasileira. Aliado a este sentimento de insegurança, também emerge a sensação de impunidade, ou seja, além da convivência forçada com a criminalidade, o brasileiro não tem garantia alguma de que os infratores serão de fato punidos com as devidas sanções, o que serve tanto de motivação para aqueles indivíduos engajados em atividades criminosas, quanto combustível ao crescimento da desconfiança da população em relação a mudanças de curto prazo neste cenário (Mariani (2011)).

Em virtude do crescimento da criminalidade, as autoridades buscam alternativas para reduzir os índices de criminalidade, violência e medo. No Brasil a preocupação em definir métodos e adotar medidas para melhorar a qualidade de vida da sociedade está agora se desvencilhando unicamente da ação da polícia e seu maior monitoramento nas ruas. É evidente que a atuação dos policiais é efetivamente importante, mas atitudes conjuntas da comunidade, artifícios da tecnologia e do desenho urbano também podem colaborar com a queda dos índices de criminalidade nos centros urbanos.

Os sistemas de circuito fechado de televisão (CCTV) já são amplamente utilizados em edifícios, empresas, condomínios e shopping centers. Mas agora, as câmeras de

televisão, já estão sendo adotadas nas ruas das cidades. Estas câmeras, devem ser avaliadas quanto ao seu poder de inibir atos criminosos, de prisão de criminosos e no aumento da percepção de segurança da comunidade. Segundo Brown (1997), em seu relatório sobre CCTV em centros urbanos para o *Home Office Police Research Group*, as câmeras aumentam a capacidade de vigilância agindo como:

- apoio eficiente no patrulhamento dos centros urbanos, dependendo do lugar onde estiverem instaladas;
- auxílio na identificação e prisão de suspeitos;
- desencorajador de atos criminosos;
- auxílio no monitoramento do comportamento da própria polícia.

Como exemplo de utilização do CCTV, pode-se citar as cidades inglesas Newcastle e Birmingham, pioneiras a adotarem esse sistema de vigilância. Nessas duas grandes cidades da Inglaterra a instalação de câmeras iniciou-se a partir de iniciativas locais na década de 80, inicialmente localizadas nos centros urbanos onde a maioria dos estabelecimentos comerciais estão localizados. Inicialmente esse sistema teve uma grande influência na diminuição do número de crimes, mas algumas delas começaram a não influenciar após um certo período de tempo. Na verdade o impacto das câmeras variou com o tipo de crime.

No Brasil, os sistemas de circuito fechado de televisão já são utilizados em algumas cidades. Em 2003, um projeto de monitoramento por câmeras foi iniciado em Copacabana no Rio de Janeiro e na Região Metropolitana de Campinas, São Paulo. Em Minas Gerais, um projeto piloto foi testado entre dezembro de 2002 e fevereiro de 2003 e, posteriormente, implantado em 14 de janeiro de 2004.

Um dos grandes benefícios dos sistemas de câmeras de vigilância é a potencialização da ação da polícia, colaborando para as cidades se tornarem ambientes mais seguros, inibindo a violência e criminalidade.

Segundo Gill and Spriggs (2005), em relatório sobre a avaliação do impacto de CCTV para o *Home Office*, as câmeras de CCTV são mais eficazes na redução de crimes contra a propriedade, em vez de crime contra a pessoa. Eles também apontaram que o efeito global da câmera pode ser um deslocamento dos crimes para outras regiões, em vez

de uma redução absoluta da atividade criminosa. Já Armitage (2002) relatou que o efeito das câmeras pode desaparecer após um período de tempo, particularmente se a divulgação não for mantida. Outros estudos sobre o efeito de sistemas de CCTV incluem dois livros: um publicado por McCahill (2002) onde discute o rápido crescimento dos sistemas de CCTV e o outro escrito por Norris and Armstrong (1999), onde realizam uma extensa pesquisa de campo sobre vigilância de circuitos fechados de televisão.

## 2.3 Inferência Bayesiana

Um dos principais objetivos da inferência estatística é conseguir conclusões sobre quantidades não observadas. Isso é feito a partir de um conjunto de informações disponíveis sobre a quantidade de interesse (vamos supor  $\theta$ ). O verdadeiro valor de  $\theta$  é desconhecido e a idéia, sob o enfoque Bayesiano, é representar esse grau de incerteza através de modelos probabilísticos para  $\theta$ . Assim, é natural que diversos pesquisadores tenham diferentes graus de incerteza sobre  $\theta$  e, dessa forma, as quantidades observáveis e os parâmetros de um modelo estatístico são considerados quantidades aleatórias.

Nessa seção são apresentados conceitos básicos da inferência Bayesiana necessários para o entendimento da dissertação. Para um estudo aprofundado e detalhado sobre o tema ver Casella and Robert (2010), Bernardo and Smith (1994) e Migon and Gamerman (1999).

### 2.3.1 Teorema de Bayes

Na inferência Bayesiana, a incerteza do pesquisador diante do valor desconhecido  $\theta$  é representada pela distribuição *a priori*  $\pi(\theta)$ . Essa informação sobre  $\theta$  pode ser atualizada observando-se uma quantidade aleatória  $X$  relacionada com  $\theta$ . Essa relação é definida pela distribuição amostral  $f(X|\theta)$ . A atualização da informação sobre  $\theta$ , após observar  $X = x$ , é bastante intuitiva e, o teorema de Bayes, é a regra utilizada para quantificar essa atualização da informação,

$$\pi(\theta|x) = \frac{f(\theta, x)}{f(x)} = \frac{f(X|\theta)\pi(\theta)}{f(x)} = \frac{f(X|\theta)\pi(\theta)}{\int f(X|\theta)\pi(\theta)d(\theta)}.$$

Observa-se que a parcela  $1/f(x)$ , que não depende de  $\theta$ , representa a constante normalizadora de  $\pi(\theta|x)$ .

Para um valor fixo de  $x$ ,  $f(x|\boldsymbol{\theta})$  fornece a verossimilhança de cada um dos possíveis valores de  $\boldsymbol{\theta}$  enquanto  $\pi(\boldsymbol{\theta})$  representa a distribuição *a priori*, que descreve a informação que temos sobre  $\boldsymbol{\theta}$  antes da observação dos dados. Estas duas fontes de informação, verossimilhança e distribuição *a priori*, são combinadas levando a distribuição *a posteriori* de  $\boldsymbol{\theta}$ ,  $\pi(\boldsymbol{\theta}|x)$ .

### 2.3.2 Distribuições *a priori*

A utilização de informação *a priori* em inferência Bayesiana requer que seja especificada uma distribuição *a priori* para o parâmetro de interesse. Essa distribuição deve representar probabilisticamente todo o conhecimento prévio que se tem sobre o parâmetro antes da realização do estudo. A partir desse conhecimento, pode-se definir uma família paramétrica de densidades. Nesse caso a distribuição *a priori* é representada de forma funcional, cujos parâmetros deverão ser especificados de acordo com esse modelo. Tais parâmetros indexadores são chamados de hiperparâmetros, para diferenciá-los dos parâmetros de interesse.

Existem diferentes formas de especificação da distribuição *a priori*. Uma dessas, é escolher a forma funcional da distribuição *a priori*, de modo que pertença à mesma família de distribuições da *posteriori*, as chamadas famílias de distribuições conjugadas. A vantagem, ao utilizar tais famílias, está refletida na facilidade de análise.

Outra forma de especificar tais distribuições é utilizar o mínimo de informação *a priori*, deixando dessa forma que os dados determinem a região de maior massa de probabilidade *a posteriori*. Este é o conceito das chamadas distribuições *a priori* não-informativas ou de referência.

A primeira idéia de não-informação *a priori* é pensar em todos os possíveis valores de  $\boldsymbol{\theta}$  como igualmente prováveis, isto é, com uma distribuição *a priori* uniforme. Neste caso, fazendo  $\pi(\boldsymbol{\theta}) \propto k$  para  $\boldsymbol{\theta}$  variando em um subconjunto da reta, significa que nenhum valor particular tem preferência (Ehlers and Justiniano (2003)). Outra maneira relativamente simples de definir distribuições *a priori* não informativas é escolher distribuições de forma que o parâmetro de interesse possua uma variância bastante elevada.

### 2.3.3 Distribuição *a posteriori*

A distribuição *a posteriori* contém toda a informação probabilística dos parâmetros que deseja-se fazer inferência, sendo a melhor descrição do processo de inferência Bayesiana. Esta pode ser obtida através de métodos analíticos ou simulação. Os métodos analíticos envolvem múltiplas integrais, quase impossíveis de serem solucionadas. Devido a tal fato, que a estatística Bayesiana ganha importância prática quando métodos computacionais tornam possíveis a geração de milhares de simulações em curto período de tempo. Geralmente os métodos de Monte Carlo via cadeias de Markov (MCMC, na abreviação em inglês) são uma alternativa para solução de tais problemas. Na subseção 2.3.4 estão apresentados os métodos utilizados nesse trabalho.

### 2.3.4 Técnicas de Monte Carlo via Cadeias de Markov

Os métodos MCMC realizam integração numérica através de simulação estocástica. A idéia básica é gerar amostras da distribuição de interesse a partir de distribuições de transição da cadeia que devem ser escolhidas de tal forma que a cadeia gerada convirja para a distribuição *a posteriori* conjunta dos parâmetros do modelo, denominada distribuição estacionária. O objetivo é gerar uma amostra que seja suficientemente grande, a partir dessa distribuição estacionária, e que aproxime bem a distribuição *a posteriori* conjunta exata. Para isso estipula-se um *burn-in* que é o período de aquecimento da cadeia, o *lag* que minimiza a autocorrelação da cadeia gerada e, a partir disso, tem-se uma amostra que é suficiente para se obter uma boa aproximação para a distribuição de interesse.

Nesta seção serão apresentados o amostrador de *Gibbs* e o algoritmo de *Metropolis-Hastings*, utilizados na inferência Bayesiana dos modelos propostos nesta dissertação. Uma ampla discussão destes e de outros métodos, com sua aplicação em diversos modelos, é encontrada em Gamerman and Lopes (2006).

- ***Metropolis-Hastings***

O algoritmo *Metropolis-Hastings* foi apresentado por Metropolis et al. (1953) e posteriormente estendido por Hastings (1970), resultando o algoritmo de Metropolis-Hastings. O método é usado para a gerar de amostras da distribuição dos parâmetros de interesse, cujas condicionais completas não tenham forma analítica fechada.

Nesse caso, são gerados valores para cada parâmetro a partir de uma distribuição auxiliar, chamada de distribuição proposta  $q()$ , tais valores são aceitos ou não com uma certa probabilidade. O algoritmo Metropolis-Hastings possui a seguinte estrutura:

1. Escolher o número  $n$  de etapas (passos da cadeia);
2. Inicialize o contador de iterações da cadeia em  $j = 1$  e atribua um valor inicial  $\theta^{(j)}$ ;
3. Gerar um valor  $\theta'$  de uma distribuição proposta  $q(\theta'|\theta)$ . Esta distribuição proposta pode depender do estado atual da cadeia;
4. Gerar  $u \sim U(0; 1)$  (distribuição *a priori*);
5. Determinar a probabilidade de aceitação  $\alpha(\theta; \theta')$  dada por:

$$\alpha(\theta; \theta') = \min \left\{ 1; \frac{f(x|\theta')\pi(\theta')q(\theta|\theta')}{f(x|\theta)\pi(\theta)q(\theta'|\theta)} \right\} \quad (2.1)$$

6. Se  $u < \alpha(\theta; \theta')$  então o valor de  $\theta'$  é aceito e  $\theta^{(j)} = \theta'$ . Caso contrário  $\theta'$  é rejeitado e  $\theta^{(j)} = \theta^{(j-1)}$ ;
7. Se  $j = n$ , ir para o passo 10;
8. Incrementar  $j$ , fazendo  $j = j + 1$ ;
9. Voltar ao passo 3;
10. FIM.

- **Amostrador de *Gibbs***

O algoritmo amostrador de *Gibbs* (Geman and Geman (1984)) foi proposto por Gelfand and Smith (1990), para aproximar a distribuição *a posteriori*. Este algoritmo é um esquema iterativo de amostragem de uma cadeia de Markov, cujo núcleo de transição é formado pelas distribuições condicionais completas dos parâmetros que serão estimados. Suponha que pretende-se estimar os parâmetros  $\theta_1, \dots, \theta_p$  e admita que as distribuições condicionais completas são conhecidas. Dadas as distribuições condicionais completas  $\pi(\theta_1|\theta_2, \dots, \theta_p)$ ,  $\pi(\theta_2|\theta_1, \theta_3, \dots, \theta_p)$ ,  $\dots$ ,  $\pi(\theta_p|\theta_1, \dots, \theta_{p-1})$  o algoritmo *Gibbs Sampling* tem a seguinte estrutura:

1. Inicialize o contador de iterações da cadeia de Markov fazendo  $j = 1$  e arbitre valores iniciais:  $\boldsymbol{\theta}^{(0)} = (\theta_1^{(0)}, \dots, \theta_p^{(0)})$ ;

2. Obtenha o  $j$ -ésimo valor  $\boldsymbol{\theta}^{(j)} = (\theta_1^{(j)}, \dots, \theta_p^{(j)})$ ,  $j = 1, 2, \dots, n$  a partir de  $\boldsymbol{\theta}^{(j-1)}$  através de sucessivas gerações de valores:

$$\theta_1^{(j)} \sim \pi(\theta_1 | \theta_2^{(j-1)}, \dots, \theta_p^{(j-1)})$$

$$\theta_2^{(j)} \sim \pi(\theta_2 | \theta_1^{(j)}, \theta_3^{(j-1)}, \dots, \theta_p^{(j-1)})$$

(...)

$$\theta_p^{(j)} \sim \pi(\theta_p | \theta_1^{(j)}, \dots, \theta_{p-1}^{(j)})$$

3. Mude o contador de  $j$  para  $j + 1$  e retorne a 1.

Portanto, o algoritmo de *Gibbs* é um tipo de MCMC com taxa de aceitação de 100%. A simulação a partir das distribuições condicionais de cada parâmetro pode ser generalizada caso a distribuição condicional de alguns dos parâmetros não tenha forma conhecida. Neste caso, pode-se usar o algoritmo de Metropolis-Hastings e, neste caso, dizemos que implementamos *Gibbs* com passo de *Metropolis-Hastings*. Caso que será desenvolvido nesse estudo.

## 2.4 Recursos Computacionais

Neste trabalho utilizaremos o *software* R (R Core Team (2014)) para a realização das análises que compõem o estudo.

O R é uma linguagem e um ambiente computacional utilizado para o desenvolvimento de análises estatísticas e técnicas gráficas. Ele possui uma infinidade de técnicas estatísticas implementadas, mas um aspecto de extrema importância é a enorme capacidade de visualização de dados, que permite ao usuário grande flexibilidade no desenvolvimento e apresentação dos dados. Outro aspecto que vale destaque é a integração do R com outras linguagens de programação e também com outros *softwares*, o que permite a otimização de alguns procedimentos. Entre as linguagens tem-se o C, C++ e FORTRAN e, entre os *softwares* pode-se citar Microsoft Excel, OpenBugs e Statistical Analysis System (SAS).

Em muitas situações, dependendo da complexidade do problema em estudo, a compilação de um código no R não é rápida o suficiente para produzir resultados em tempo hábil. Visando solucionar situações como essa, neste trabalho, utilizaremos o R concomitante a outras ferramentas. O presente estudo apresenta grande conjunto de dados e muitos parâmetros para serem estimados (via métodos MCMC), assim, devido a essa

complexidade e a testes realizados, foi possível notar que somente o R não seria capaz de fornecer resultados que possibilitassem o cumprimento do prazo necessário.

Dessa forma, algumas alternativas foram testadas para encontrar a melhor forma de analisar os dados, sempre aliadas ao R. A primeira, foi a utilização do *software* OpenBugs, que possui uma linguagem similar à do R e permite a análise de modelos estatísticos complexos usando MCMC. Para utilizá-lo o usuário deve especificar o modelo a ser executado, além de carregar os dados e os valores iniciais para o modelo. Após a execução, é possível salvar os resultados dos parâmetros de interesse para posteriormente realizar a análise desejada, no próprio programa ou no R (Sturtz et al. (2005)). Através dessa implementação, não foi possível obter os resultados esperados. O tempo de execução foi muito grande, para um número de iterações pequeno, que não levava à convergência da cadeia.

A segunda tentativa foi a utilização do pacote *Nimble* (NIMBLE Development Team (2014)), que estende a linguagem do OpenBugs tornando-a mais flexível. Ele permite a construção e utilização da linguagem R para programar, processa o código em C++ e carrega os resultados automaticamente no R. Mas, utilizando esse pacote, não foi possível obter nenhum resultado. Devido a falta de materiais disponíveis para auxiliar na solução dos erros, nem mesmo a compilação pode ser completada, tornando a utilização do pacote inviável.

A terceira e última tentativa foi utilizar o pacote Rcpp (Eddelbuettel and Francois (2011)), que possibilita uma conexão rápida e simples do R ao C++, otimizando a compilação, além de facilitar a manipulação de estruturas de dados, tais como vetores, *loops* e funções. Basicamente, para utilização do pacote Rcpp, é necessário construir o código no R, usando a linguagem C++ e, ao compilar esse código, a ferramenta constrói uma *interface* no R que se conecta a função compilada em C++. Essa foi a solução para realizar a análise e obter resultados deste estudo.

Para exemplificar o funcionamento do Rcpp e a velocidade com que um algoritmo é compilado, um pequeno exemplo foi implementado, construindo um código utilizando as linguagens R, C e Rcpp (C++). Tal código trata-se da multiplicação de duas matrizes, uma de dimensão 300 x 500 e outra 500 x 700. Os *scripts* utilizados estão descritos no Apêndice A.

Tabela 2.1: Tempo (em segundos) de execução da multiplicação de duas matrizes em R, Rcpp (C++) e C.

<b>R</b>	<b>Rcpp(C++)</b>	<b>C</b>
2.405	0.168	0.139

A Tabela 2.1 apresenta os tempos de execução para cada uma das três linguagens: R, C e Rcpp (C++). Observa-se que o tempo gasto pelo Rcpp foi próximo do tempo gasto pelo C, mas distante do tempo gasto pelo R. Nota-se que o tempo gasto pelo R é 18 vezes maior que o tempo gasto pelo Rcpp. Para códigos de alta complexidade, o tempo de execução sofrerá uma redução drástica. Dessa forma, toda implementação apresentada no Capítulo 4 será feita utilizando o pacote Rcpp.

## 3 Materiais e Métodos

Nesta seção, discorre-se sobre o banco de dados e a metodologia estatística a ser empregada na análise dos mesmos.

### 3.1 Descrição dos Dados

Para a análise a ser realizada nesse trabalho, serão utilizadas informações de crimes contra a pessoa coletados no bairro Centro, do município de Belo Horizonte, Minas Gerais. Os dados foram registrados por câmeras de circuito fechado de televisão (CCTV) instaladas no referido bairro, e que fazem parte do programa Olho Vivo da prefeitura de Belo Horizonte. A Figura 3.1 mostra em destaque o bairro Central no município de Belo Horizonte.




Figura 3.1: Mapa do município de Belo Horizonte, em destaque o bairro Centro.

O banco de dados é composto por 16.614 registros de crimes que ocorreram entre 01 de janeiro de 2002 e 31 de dezembro de 2006, cada um com sua respectiva latitude, longitude, dia, mês, ano, hora e endereço de ocorrência. A Figura 3.2 mostra a distribuição dos registros na região em estudo.




Figura 3.2: Distribuição dos crimes contra pessoa no bairro Centro de Belo Horizonte.

Além disso, dispõe-se da localização das 60 câmeras de CCTV, como pode ser verificado através da Figura 3.3, que foram instaladas no dia 13 de dezembro de 2004 na mesma região.

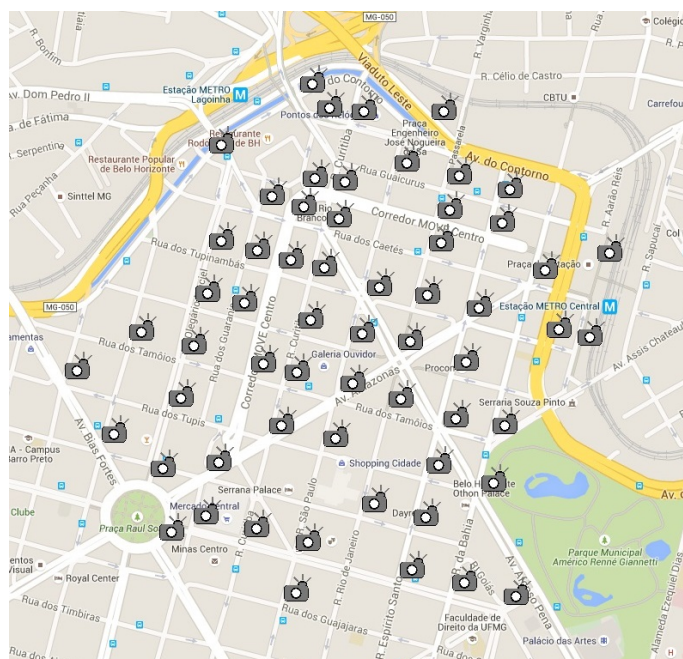


Figura 3.3: Localização das câmeras no bairro Centro de Belo Horizonte.

Dessa forma, considera-se a instalação das câmeras como uma intervenção realizada no espaço em estudo, permitindo o trabalho em dois cenários: um representando os crimes que aconteceram antes da instalação das câmeras e o outro representando os crimes que aconteceram após a intervenção. Assim, tem-se que dos 16.614 eventos registrados, 12.164 ocorreram antes da intervenção e 4.450 após a mesma. A Figura 3.4 apresenta a localização dos crimes separados pela instalação das câmeras.

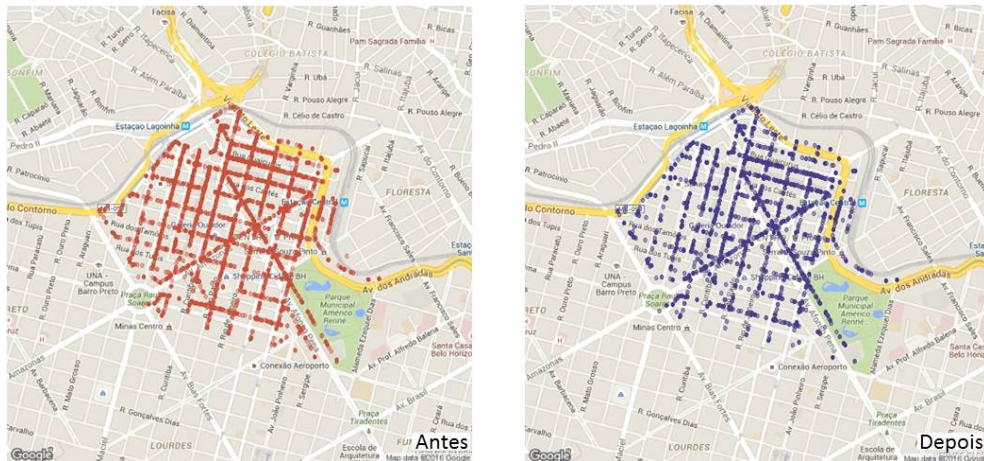


Figura 3.4: Distribuição dos crimes na região em estudo: à esquerda crimes que ocorreram antes da instalação das câmeras; à direita crimes que ocorreram após a instalação das câmeras.

Visualmente, através da Figura 3.4, não é possível obter nenhuma conclusão e/ou comparação sobre a distribuição dos crimes antes e após a intervenção.

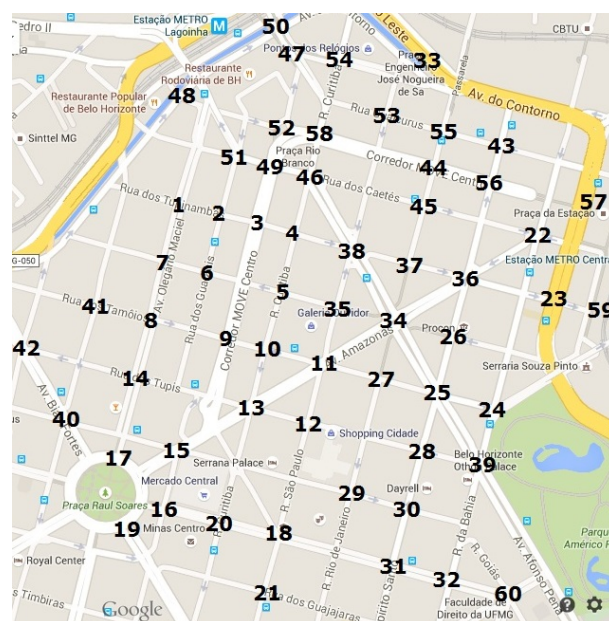


Figura 3.5: Numeração atribuída às câmeras instaladas no Centro de Belo Horizonte.

Em continuidade à descrição dos dados, para realizar a análise e facilitar a identificação das câmeras, tais foram numeradas de 1 a 60, como apresentado na Figura 3.5.

A Figura 3.6 apresenta, para cada câmera, a razão entre a proporção de crimes que aconteceram depois e antes da intervenção. Os quadrados representam as razões menores que 1 e os círculos as razões maiores que 1. Quanto maior o quadrado/círculo, mais afastada de 1 está a razão. Com o auxílio da Figura 3.5 pode-se identificar os casos de maior destaque, como por exemplo a câmera 59. Essa possui a menor razão de todas, atingindo o valor de 0.249, ou seja, a proporção de crimes que ocorreram depois da instalação é 4 vezes menor quando comparado à proporção daqueles que ocorreram antes, na mesma região. Em contrapartida, a câmera 17 é que apresenta a maior razão, igual a 2.749, ou seja, a proporção de crimes na região em que essa câmera está localizada aumentou aproximadamente 174% após a instalação das câmeras. Já as câmeras 34 e 44 foram as que apresentaram razão próxima a 1, 0.972 e 1.024 respectivamente. Logo a proporção de crimes registrados antes e após a intervenção, nas proximidades de cada câmera não sofreu praticamente nenhuma alteração.

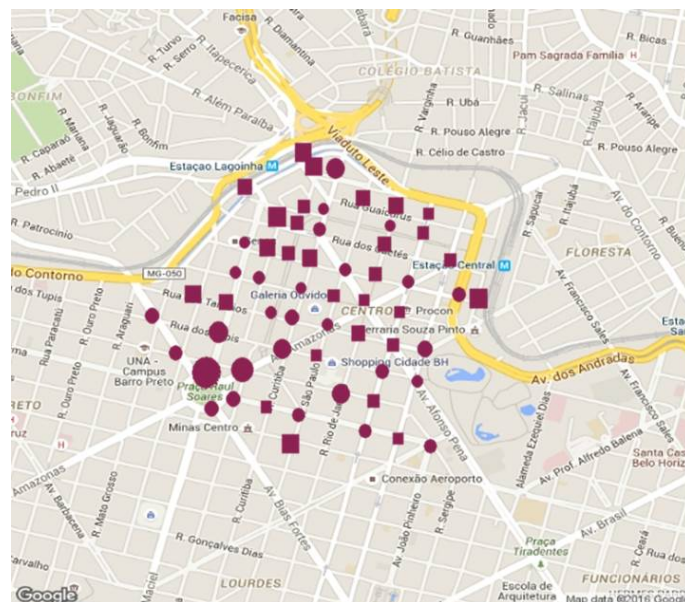


Figura 3.6: Razão entre a proporção de crimes que ocorreram depois e antes da intervenção, na vizinhança de cada câmera. O quadrado representa as razões menores que 1 e, o círculo, razões maiores que 1.

A Figura 3.7 apresenta a distribuição da quantidade dos crimes ao longo dos 25 meses após a instalação das câmeras. Observa-se que há uma pequena redução na

quantidade dos crimes com o passar dos meses, mas sem observar um padrão aparente nesse decaimento.

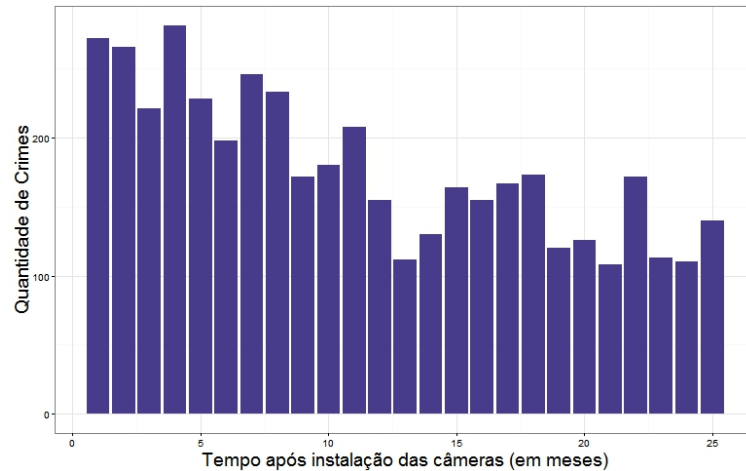


Figura 3.7: Número de crimes, por mês, após a instalação das câmeras.

Através da Tabela 3.1 confirma-se a redução gradual na quantidade de crimes apresentado pelo gráfico da Figura 3.7. Observa-se que mais de 50% dos crimes, que ocorreram nesses 25 meses após a instalação das câmeras, foram registrados do 1<sup>o</sup> ao 10<sup>o</sup> mês pós intervenção.

Tabela 3.1: Distribuição da quantidade total de crimes, após a instalação das câmeras, em intervalos de meses.

Distribuição dos meses	Quantidade de Crimes	%
1 <sup>o</sup> ao 5 <sup>o</sup>	1.268	28,5
6 <sup>o</sup> ao 10 <sup>o</sup>	1.029	23,1
11 <sup>o</sup> ao 15 <sup>o</sup>	769	17,3
16 <sup>o</sup> ao 20 <sup>o</sup>	741	16,7
21 <sup>o</sup> ao 25 <sup>o</sup>	643	14,4
<b>Total</b>	<b>4.450</b>	<b>100</b>

A Figura 3.8 apresenta o percentual (por hora do dia) dos crimes que ocorreram antes e após a instalação das câmeras. Ao compararmos essas duas situações, nota-se que a proporção de crimes antes da intervenção é superior no intervalo entre 20 horas e 5 horas. Situação que nos leva a crer que o menor fluxo de pessoas nas ruas e avenidas facilita a identificação dos crimes e criminosos pelas câmeras. Para o período de maior movimentação no Centro de Belo Horizonte, entre 6 e 19 horas, a proporção dos crimes por




Figura 3.8: Percentual de crimes, por hora do dia, que ocorreram antes e após a instalação das câmeras.

hora é maior pós intervenção. Assim, pressupõe-se que com a instalação das câmeras de segurança, os crimes ocorrem com maior frequência durante o dia, onde o movimento de pessoas é maior e a identificação dos criminosos se torna mais complicada. Vale ressaltar que, antes da intervenção, mais de 56% dos crimes ocorriam no intervalo entre 20 e 5 horas, após a instalação este número caiu para menos de 50%. Esses números não indicam uma migração no horário dos crimes, mas sim um comportamento menos discrepante durante as horas do dia, após a instalação das câmeras.

## 3.2 Formulação do Modelo

### 3.2.1 Metodologia Inicial

A metodologia empregada neste trabalho é uma extensão do modelo proposto por Rodrigues et al. (2010). Nesse artigo eles analisam o mesmo conjunto de dados utilizado na presente dissertação, com o objetivo de verificar, se existir, a alteração na distribuição espacial dos crimes, após a instalação das câmeras, ignorando qualquer variação temporal. Para a construção do modelo, considera-se que os eventos são gerados por um processo de Poisson pontual. Dessa forma, os controles e os casos foram modelados como um processo de Poisson bivariado, e tratados como um par de amostras aleatórias independentes com densidades:

$$\lambda_{CO} = \frac{\lambda_0(x)}{\int \lambda_0(x) dx} \quad \lambda_{CA} = \frac{\lambda_{CO}(x)f(x)}{\int \lambda_{CO}(x)f(x) dx} \quad (3.1)$$

onde  $\lambda_0(x)$  é a função de intensidade da população em risco,  $\lambda_{CO}$  é a densidade dos controles,  $\lambda_{CA}$  é a densidade dos casos e  $f(x)$  é o efeito espacial das câmeras na distribuição dos crimes. Tem-se que  $\int \lambda_{CO}(x)f(x)dx$  pode ser estimado por  $E[f(x)]$ .

Para modelar o efeito espacial das câmeras na distribuição dos crimes, propõe-se o seguinte modelo:

$$f(x) = g_{i(x)}(\|x - x_{0,i(x)}\|)g_{j(x)}(\|x - x_{0,j(x)}\|) \quad (3.2)$$

onde para cada  $x$ ,  $i(x)$  e  $j(x)$  representam as câmeras que delimitam o segmento de rua ao qual  $x$  pertence. Se  $x$  está presente em um segmento que não é delimitado por duas câmeras, assume-se que  $f(x) = g_{i(x)}(\|x - x_{0,i(x)}\|)$ , onde  $i(x)$  identifica a câmera mais próxima ao evento  $x$ .

Como a metodologia apresentada se desenvolve apenas com base na esfera espacial e, dada a importância atual da modelagem espaço-temporal para o estudo de questões de grande importância para a sociedade, neste trabalho realizaremos a extensão espaço-temporal do modelo apresentado.

### 3.2.2 Extensão da Metodologia

Suponha que a instalação das câmeras aconteça no tempo  $t_0$ . Dessa forma, para a construção do modelo, considera-se que os eventos ocorreram em dois períodos distintos, a saber:

- $t < t_0$ : eventos que ocorreram antes da instalação das câmeras;
- $t \geq t_0$ : eventos que ocorreram após instalação das câmeras.

Dessa forma, assume-se que os eventos seguem um processo de Poisson com função intensidade dada por:

$$\begin{aligned} \Lambda(x, t) &= \eta(t) \left\{ [1 - g(t)] \lambda(x) + g(t) \frac{\lambda(x)f(x)}{\int \lambda(x)f(x)d(x)} \right\} \\ &= \eta(t) \lambda(x) \left\{ 1 - g(t) \left[ 1 - \frac{f(x)}{\int \lambda(x)f(x)d(x)} \right] \right\} \end{aligned} \quad (3.3)$$

onde  $\eta(t)$  representa o número de eventos que ocorreram no tempo  $t$  e  $\lambda(x)$  é a função densidade de probabilidade sob a região em estudo, que representa a distribuição espacial dos eventos antes da intervenção ocorrer. A função  $g(t)$  modela o efeito temporal da

instalação das câmeras na distribuição dos eventos. E,  $f(x)$ , é a função que modela o efeito espacial da instalação das câmeras na distribuição dos crimes, com  $\frac{f(x)}{\int \lambda(x)f(x)d(x)}$  representando o efeito máximo da intervenção na distribuição  $\lambda(x)$ , quando  $g(t) = 1$ .

Observa-se que, para qualquer tempo  $t$ , modelamos a distribuição espacial dos eventos como uma média ponderada de  $\lambda(x)$  e  $\frac{\lambda(x)f(x)}{\int \lambda(x)f(x)d(x)}$ , com pesos  $1 - g(t)$  e  $g(t)$  respectivamente. Ou seja, trata-se de uma média ponderada entre a taxa dos eventos que ocorreram antes da intervenção e a intervenção máxima  $f(x)$  ocorrida naquela localização.

Para modelar a função  $g(t)$ , propõe-se um modelo paramétrico:

$$g(t) = \begin{cases} 0, & \text{se } t < t_0 \\ \left[ \frac{(t - t_0)}{\theta_1} \right]^{\theta_2}, & \text{se } t_0 \leq t < \theta_1 \\ 1 - \theta_3 \left\{ 1 - \left[ \frac{(T - t)}{T - \theta_1} \right]^{\theta_4} \right\}, & \text{se } t \geq \theta_1 \end{cases} \quad (3.4)$$

onde:

- $\theta_1 \in (t_0, T)$ : tempo decorrido até atingir o pico máximo da intervenção;
- $\theta_2 \in \mathbb{R}^+$ : parâmetro de forma;
- $\theta_3 \in [0, 1]$ : proporção não-efetiva da intervenção;
- $\theta_4 \in \mathbb{R}^+$ : parâmetro de forma;
- $t_0$ : tempo no qual as câmeras foram instaladas.

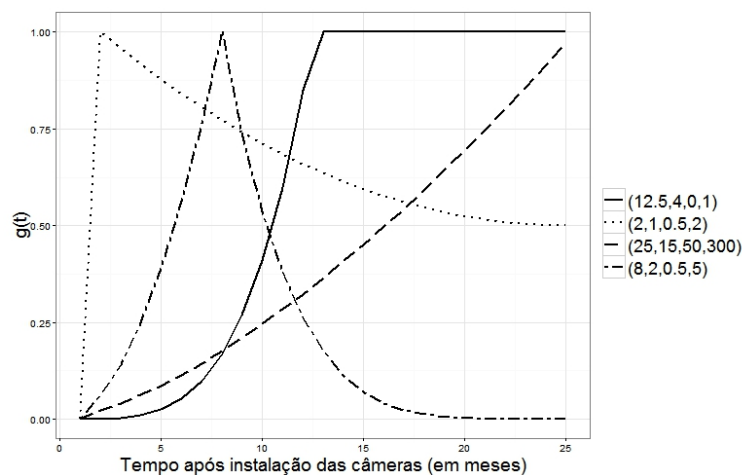


Figura 3.9: Função  $g(t)$  para diferentes combinações dos parâmetros  $(\theta_1, \theta_2, \theta_3$  e  $\theta_4)$ .

A Figura 3.9 mostra a função  $g(t)$  para diferentes valores dos parâmetros  $\theta_1$ ,  $\theta_2$ ,  $\theta_3$  e  $\theta_4$ . Como mencionado anteriormente, observa-se que o parâmetro  $\theta_1$  representa

o tempo no qual as câmeras atingiram o efeito máximo da intervenção, fato comprovado pelas curvas dispostas no gráfico. Vale destacar, o comportamento das curvas quando observamos o parâmetro  $\theta_3$ . Nota-se que a medida que o valor desse parâmetro aumenta, a efetividade das câmeras vai diminuindo. Quando seu valor é igual a 0, significa que as câmeras foram 100% efetivas após o pico máximo de efetividade. Já quando é igual a 1, temos que as câmeras não foram mais efetivas após atingir o pico máximo.

Dessa forma, pode-se reescrever a Equação (3.3) para os dois períodos em estudo separadamente: antes e após a instalação das câmeras. Assim, obtém-se que antes da intervenção os eventos seguem um processo de Poisson com função intensidade dada por:

$$\Lambda(x, t) = \eta(t)\lambda(x), \quad t < t_0 \quad (3.5)$$

Da mesma forma, os eventos que ocorreram após a instalação das câmeras seguem um processo de Poisson. Entretanto, a intervenção modifica a função intensidade dada em (3.5), como segue:

$$\Lambda(x, t) = \eta(t)\lambda(x) \left\{ 1 - g(t) \left[ 1 - \frac{f(x)}{\int \lambda(x)f(x)d(x)} \right] \right\}, \quad t \geq t_0 \quad (3.6)$$

onde define-se  $h(x, t) = 1 - g(t) \left[ 1 - \frac{f(x)}{\int \lambda(x)f(x)d(x)} \right]$  como uma função que representa o efeito espaço-temporal da instalação das câmeras na distribuição dos crimes.

Considerando  $Y_A$  como eventos que ocorreram antes da intervenção,  $Y_D$  eventos que ocorreram após a instalação das câmeras e, supondo independência dos processos, tem-se que,

$$Y_A + Y_D \sim Poisson \left( \sum_{t=0}^1 \Lambda(x, t) \right) \quad (3.7)$$

sendo  $t = 0$  eventos que ocorreram antes da instalação das câmeras e  $t = 1$  eventos que ocorreram após a intervenção.

Condicionado na ocorrência de um evento, tem-se que a probabilidade de um evento ocorrer antes da instalação das câmeras é dada por:

$$\begin{aligned}
 P(Y_A = 1|Y_A + Y_D = 1) &= \frac{P(Y_A = 1 \cap Y_A + Y_D = 1)}{P(Y_A + Y_D = 1)} & (3.8) \\
 &= \frac{P(Y_A = 1 \cap Y_D = 0)}{P(Y_A + Y_D = 1)} \\
 &= \frac{e^{-\Lambda_0} \Lambda(x, 0)^1 e^{-\Lambda(x, 1)} \Lambda(x, 1)^0}{\frac{1!}{e^{-(\Lambda(x, 0) + \Lambda(x, 1))}} (\Lambda(x, 0) + \Lambda(x, 1))^1} \\
 &= \frac{\Lambda(x, 0)}{\sum_{t=0}^1 \Lambda(x, t)}
 \end{aligned}$$

Segue do resultado apresentado na Equação (3.9),

$$P(Y_D = 1|Y_A + Y_D = 1) = 1 - P(Y_A = 1|Y_A + Y_D = 1) \quad (3.9)$$

Em virtude do resultado apresentado, pode-se associar a cada crime uma variável Bernoulli, ou seja, o evento possui determinada probabilidade  $p$  de acontecer após a instalação das câmeras e  $1 - p$  de ocorrer antes da instalação das câmeras.

Ao transformar o processo de Poisson em variáveis do tipo Bernoulli, a estimação das funções de intensidade, que não são triviais, passam a ser dispensáveis, viabilizando dessa forma o processo de cálculo das estimativas.

Para adotar tal metodologia ao problema apresentado nesse trabalho, algumas modificações devem ser realizadas. Sabe-se que a ocorrência ou não de um crime não é analisada apenas nos tempos antes e após a instalação das câmeras. Analisa-se sua ocorrência antes da intervenção ou em cada um dos meses subsequentes a instalação das câmeras, dentro do período de análise.

Dessa forma generaliza-se o modelo binomial, e os crimes que eram analisados apenas nos tempos antes e após a instalação das câmeras, passam a ser analisados em cada um dos  $t$  tempos após a instalação, sendo que cada tempo possui sua respectiva probabilidade de ocorrência  $p_0, \dots, p_T$ , resultando em uma distribuição multinomial.

Pelo exposto, para modelar a distribuição espaço-temporal dos crimes que ocorreram na região central da cidade de Belo Horizonte, utilizou-se a distribuição multinomial:

$$Y_{x,t} \sim M_T(1, p(x, 0) \dots p(x, T)) \quad (3.10)$$

onde  $Y_{x,t}$  representa a ocorrência de determinado crime na localização  $x$  no tempo  $t$ ,  $p(x,t)$  é a probabilidade de ocorrência do crime na localização  $x$  no tempo  $t$  e  $T$  é o tempo máximo (em meses) no qual foi registrado um evento. Tal probabilidade é representada como segue:

$$p(x,t) = \frac{h(x,t)\eta(t)}{\eta(0) + \sum_{j=1}^T h(x,j)\eta(j)} \quad (3.11)$$

sendo  $\eta(0)$  representa o número de crimes registrados antes da instalação das câmeras,  $\eta(t)$  o número de eventos que ocorreram tempo  $t$ ,  $T$  é o tempo máximo (em meses) no qual foi registrado um evento e  $h(x,t)$  é o efeito espaço-temporal da intervenção.

Para modelar o efeito espacial da intervenção na distribuição dos eventos, considera-se que a função  $f(x)$  irá depender da distância das câmeras mais próximas ao evento  $x$ , mais precisamente aquelas que delimitam o segmento de rua em que o crime ocorreu. Se o evento  $x$  está localizado em um segmento que é delimitado por apenas uma câmera, assume-se:

$$f(x) = \exp(\gamma)s_i(\|x - x_{0,i}\|), \quad i = 1, \dots, 60 \quad (3.12)$$

onde  $i$  identifica a câmera mais próxima à ocorrência do evento.

Se o crime for identificado em um segmento de rua delimitado por duas câmeras, a função  $f(x)$  será modelada por

$$f(x) = \exp(\gamma)s_i(\|x - x_{0,i}\|)^{w_i(x)}s_j(\|x - x_{0,j}\|)^{w_j(x)} \quad (3.13)$$

onde para cada  $x$ ,  $i$  e  $j$  identificam as câmeras pertencentes a cada extremidade da rua em que o evento está localizado e  $s$  são funções não-paramétricas.

Visando evitar mudanças bruscas no valor de  $f(x)$  quando  $x$  passa de um segmento para outro, calcula-se a função como uma média geométrica ponderada de  $s_i(x)$  e  $s_j(x)$ , com pesos  $w_i(x) = \frac{(\|x - x_{0,j}\|)}{(\|x - x_{0,i}\| + \|x - x_{0,j}\|)}$  e  $w_j(x) = 1 - w_i(x)$ , respectivamente. Tem-se que  $\|x - x_{0,i}\|$  é a distância do local em que ocorreu o crime até a câmera que está mais próxima ao evento  $x$  e  $\|x - x_{0,j}\|$  a distância do evento  $x$  à câmera que pertence à outra extremidade da rua em que o crime está localizado.

Para modelar as funções  $s$  utiliza-se *splines*, um tipo de função de suavização, definida como polinômio segmentado, que permite o ajuste de modelos em que as covariáveis não possuem relação linear com a variável resposta, respeitando sua forma funcional.

Tais funções, oriundas do cálculo numérico, despertaram a atenção nos estudos estatísticos por permitir flexibilidade na relação entre as variáveis e pelo seu poder adaptativo na aproximação de funções. A curva de suavização *spline* é formada pelo ajuste de curvas parciais unidas por pontos denominados nós.

Existem vários tipos de *splines*, como por exemplo, *spline* quadrático, *spline* cúbico, *spline* natural, *B-spline*, *spline* penalizado, dentre outros. Independente do tipo de *spline*, uma importante escolha a ser feita é o número de nós, pois este afeta significativamente o formato do ajuste. Quando o número de nós é muito grande pode ocorrer um super ajuste do modelo, ou *overfitting*. Neste caso, a curva passa por todos os pontos, obtendo um ajuste perfeito, mas sem passar nenhum tipo de informação. Uma solução para o super ajuste é o uso de *splines* penalizados, ou *splines* de suavização. No presente estudo será utilizado o *spline* penalizado cúbico, que pode ser escrito como segue

$$s_c(x) = \exp \left\{ \beta_{0,c} + \beta_{1,c}x + \sum_{k=1}^K \nu_{k,c} |x - z_k|^3 \right\}, c = 1, \dots, 60 \quad (3.14)$$

onde, para cada  $c$ ,  $(\beta_{0,c}, \beta_{1,c}, \nu_{1,c}, \dots, \nu_{K,c})$  é um vetor de coeficientes de regressão e,  $z_1 < \dots < z_k$  são os nós.

Seguindo a proposta de Rodrigues et al. (2010), que realizaram estudos para a escolha da quantidade de nós sob o mesmo banco de dados, nós utilizamos 4 nós que foram calculados de forma a representar os quartis 20%, 40%, 60% e 80% das distâncias do evento  $x$  até a câmera mais próxima.

## 3.3 Modelagem Bayesiana

Nessa seção estão especificados os modelos necessários para que sejam realizadas as inferências, sob enfoque Bayesiano, do modelo proposto. Ressaltando que o método de simulação utilizado será o amostrador de *Gibbs* com passo de *Metropolis-Hastings*.

### 3.3.1 Função de Verossimilhança

Suponha que foram observados  $\eta_0 + \eta_1$  eventos,  $\eta_0$  antes da intervenção e  $\eta_1$  após a intervenção. Para o conjuntos de dados  $(x_i, t_i)(i = 1, 2, \dots, \eta_0 + \eta_1)$ , onde  $x_i$  e  $t_i$  são respectivamente a localização espacial e o tempo de ocorrência do  $i$ -ésimo evento,

a função de verossimilhança para  $\theta_g = (\theta_1, \dots, \theta_4)$ ,  $\beta_{0,c}$ ,  $\beta_{1,c}$ ,  $\nu_{k,c}$  onde  $k = 1, \dots, 4$  e  $c = 1, \dots, 60$ , é dada :

$$L(\theta_g, \beta_{0,c}, \beta_{1,c}, \nu_{k,c}, \gamma) = \prod_x \left\{ \frac{(\sum_t y_{x,t})!}{\prod_t y_{x,t}!} \prod_t [p(x, t)]^{y_{x,t}} \right\}. \quad (3.15)$$

A Equação (3.11) apresenta a probabilidade da distribuição multinomial. Assim pode-se escrever a função de verossimilhança como

$$L(\theta_g, \beta_{0,c}, \beta_{1,c}, \nu_{k,c}, \gamma) = \prod_x \left\{ \frac{(\sum_t y_{x,t})!}{\prod_t y_{x,t}!} \prod_t \left[ \frac{h(x, t)\eta_1(t)}{\eta_0 + \sum_{j=1}^T h(x, j)\eta_1(j)} \right]^{y_{x,t}} \right\}. \quad (3.16)$$

### 3.3.2 Distribuições *a priori*

Nessa subseção serão apresentadas as distribuições *a priori* especificadas para o modelo em estudo.

- **Distribuição *a priori* para  $\theta$**

O interesse está no vetor de parâmetros  $\theta = (\theta_1, \theta_2, \theta_3, \theta_4)$ .

Para os parâmetros  $\theta_1$ ,  $\theta_2$ ,  $\theta_3$  e  $\theta_4$ , a distribuição *a priori* especificada foi a distribuição Normal. Como o parâmetro  $\theta_1$  refere-se ao tempo após a instalação das câmeras dentro no qual ocorreu o efeito máximo da intervenção, ele deverá pertencer ao intervalo  $(0, T)$ . Dessa forma, aplica-se uma transformação para que a distribuição *a priori* seja especificada corretamente. Assim:

$$\theta_1 = T * \frac{e^{\theta_{1aux}}}{1 + e^{\theta_{1aux}}}.$$

Já, como  $\theta_3$  representa a proporção não-efetiva da intervenção, deve pertencer ao intervalo  $(0, 1)$ . Logo:

$$\theta_3 = \frac{e^{\theta_{3aux}}}{1 + e^{\theta_{3aux}}}.$$

Para  $\theta_2$  e  $\theta_4$ , que são parâmetros de forma, aplica-se as seguintes transformações:

$$\theta_2 = e^{\theta_{2aux}}$$

$$\theta_4 = e^{\theta_{4aux}}.$$

Pelo exposto, os parâmetros  $\theta_{1aux}$ ,  $\theta_{2aux}$ ,  $\theta_{3aux}$  e  $\theta_{4aux}$ , possuem a seguinte distribuição de probabilidade:

$$\theta_{iaux} \sim Normal(\mu_{\theta_{iaux}}, \sigma_{\theta_{iaux}}^2)$$

onde,  $\mu_{\theta_{iaux}}$  e  $\sigma_{\theta_{iaux}}^2$  são os hiperparâmetros da distribuição do parâmetro  $\theta_{iaux}$ ,  $i = 1, \dots, 4$ .

Dessa forma, as distribuições *a priori* para  $\theta_{1aux}$ ,  $\theta_{2aux}$ ,  $\theta_{3aux}$  e  $\theta_{4aux}$  são definidas.

- **Distribuição *a priori* para  $\beta_0$ ,  $\beta_1$ ,  $\gamma$  e  $\nu$**

Os parâmetros  $\beta_0$ ,  $\beta_1$ ,  $\gamma$  e  $\nu$  possuem a seguinte distribuição de probabilidade:

$$\Upsilon \sim Normal(\mu_{\Upsilon}, \sigma_{\Upsilon}^2)$$

onde,  $\Upsilon$  representa os parâmetros  $\beta_0$ ,  $\beta_1$ ,  $\gamma$  e  $\nu$ . E,  $\mu_{\Upsilon}$  e  $\sigma_{\Upsilon}^2$  são os hiperparâmetros da distribuição dos parâmetros citados.

### 3.3.3 Distribuição *a priori* conjunta

Como  $\boldsymbol{\theta} = (\theta_1, \theta_2, \theta_3, \theta_4)$ ,  $\boldsymbol{\beta}_0 = (\beta_{0,1}, \dots, \beta_{0,60})$ ,  $\boldsymbol{\beta}_1 = (\beta_{1,1}, \dots, \beta_{1,60})$ ,  $\gamma$ ,  $\boldsymbol{\nu} = (\nu_{k,1}, \dots, \nu_{k,60})$  com  $k = 1, \dots, 4$  são considerados independentes, a distribuição *a priori* conjunta assumirá a forma:

$$\pi(\boldsymbol{\theta}, \boldsymbol{\beta}_0, \boldsymbol{\beta}_1, \gamma, \boldsymbol{\nu}) = \pi(\theta_{1aux})\pi(\theta_{2aux})\pi(\theta_{3aux})\pi(\theta_{4aux})\pi(\boldsymbol{\beta}_0)\pi(\boldsymbol{\beta}_1)\pi(\gamma)\pi(\boldsymbol{\nu}).$$

### 3.3.4 Distribuição *a posteriori*

Essa seção discorre sobre a distribuição *a posteriori* do modelo em estudo.

$$\begin{aligned} \pi(\boldsymbol{\theta}, \boldsymbol{\beta}_0, \boldsymbol{\beta}_1, \gamma, \boldsymbol{\nu} | \mathbf{Y}, \mathbf{X}, \boldsymbol{\eta}, t) &= L(\boldsymbol{\theta}, \boldsymbol{\beta}_0, \boldsymbol{\beta}_1, \gamma, \boldsymbol{\nu} | \mathbf{Y}, \mathbf{X}, \boldsymbol{\eta}, t) \pi(\boldsymbol{\theta}, \boldsymbol{\beta}_0, \boldsymbol{\beta}_1, \gamma, \boldsymbol{\nu}) \\ &= \prod_x \left\{ \frac{(\sum_t y_{x,t})!}{\prod_t y_{x,t}!} \prod_t \left[ \frac{h(x,t)\eta_1(t)}{\eta_0 + \sum_{j=1}^T h(x,j)\eta_1(j)} \right]^{y_{x,t}} \right\} \times \\ &\times \frac{1}{\sqrt{2\pi\sigma_{\theta_{1aux}}^2}} \exp \left\{ -\frac{1}{2\sigma_{\theta_{1aux}}^2} (\theta_{1aux} - \mu_{\theta_{1aux}})^2 \right\} \frac{1}{\sqrt{2\pi\sigma_{\theta_{2aux}}^2}} \exp \left\{ -\frac{1}{2\sigma_{\theta_{2aux}}^2} (\theta_{2aux} - \mu_{\theta_{2aux}})^2 \right\} \times \\ &\times \frac{1}{\sqrt{2\pi\sigma_{\theta_{3aux}}^2}} \exp \left\{ -\frac{1}{2\sigma_{\theta_{3aux}}^2} (\theta_{3aux} - \mu_{\theta_{3aux}})^2 \right\} \frac{1}{\sqrt{2\pi\sigma_{\theta_{4aux}}^2}} \exp \left\{ -\frac{1}{2\sigma_{\theta_{4aux}}^2} (\theta_{4aux} - \mu_{\theta_{4aux}})^2 \right\} \times \\ &\times \frac{1}{\sqrt{2\pi\sigma_{\gamma}^2}} \exp \left\{ -\frac{1}{2\sigma_{\gamma}^2} (\gamma - \mu_{\gamma})^2 \right\} \frac{1}{\sqrt{2\pi\sigma_{\beta_{0aux}}^2}} \exp \left\{ -\frac{1}{2\sigma_{\beta_{0aux}}^2} (\beta_0 - \mu_{\beta_{0aux}})^2 \right\} \times \\ &\times \frac{1}{\sqrt{2\pi\sigma_{\beta_{1aux}}^2}} \exp \left\{ -\frac{1}{2\sigma_{\beta_{1aux}}^2} (\beta_1 - \mu_{\beta_{1aux}})^2 \right\} \frac{1}{\sqrt{2\pi\sigma_{\nu}^2}} \exp \left\{ -\frac{1}{2\sigma_{\nu}^2} (\nu - \mu_{\nu})^2 \right\}. \end{aligned} \quad (3.17)$$

### 3.3.5 Condicionais Completas

Através da distribuição *a posteriori* (seção 3.3.4) pode-se obter as distribuições condicionais completas, que serão de extrema importância na obtenção de amostras das distribuições *a posteriori* dos parâmetros desconhecidos, possibilitando a realização de inferências. Tais distribuições estão apresentadas no Apêndice B.

## 4 Aplicação

Neste capítulo será apresentado a aplicação do modelo proposto ao conjunto de dados apresentado na Seção 3.1. Serão realizadas três análises, na primeira o modelo será aplicado ao conjunto das 60 câmeras e a todos os crimes registrados, na segunda constrói-se blocos com câmeras vizinhas no espaço e aplica-se o modelo a cada bloco com os crimes que ocorreram naquela região selecionada e, por último, aplica-se o modelo a cada câmera e aos crimes que se localizam nas proximidades da mesma. Todas as três análises serão utilizadas para verificar o comportamento da função  $g(t)$ , de como o efeito das câmeras ocorre no espaço e no espaço-tempo.

### 4.1 Estudo 1: Aplicação do modelo a todas as 60 câmeras.

Nesta seção será apresentada a aplicação do modelo considerando todas as câmeras e todos os crimes identificados pelas mesmas. Para realizar a análise e facilitar a identificação das câmeras, tais foram numeradas de 1 a 60, como apresentado anteriormente na Figura 3.5.

Como mencionado na Seção 2.3, as estimações dos parâmetros foram realizadas através de métodos MCMC, especificamente o método *Gibbs Sampling* com passos de *Metropolis-Hastings*. Tal método foi utilizado por permitir que componentes que não possuem formas fechadas das distribuições condicionais completas, sejam geradas de uma sub-cadeia de *Metropolis-Hastings* dentro do ciclo amostral de *Gibbs Sampling*.

Dessa forma, adotou-se tal método para atualizar os parâmetros  $\theta_g = (\theta_1, \theta_2, \theta_3, \theta_4)$ ,  $\beta_0 = (\beta_{0,1}, \dots, \beta_{0,60})$ ,  $\beta_1 = (\beta_{1,1}, \dots, \beta_{1,60})$ ,  $\nu_k = (\nu_{k,1}, \dots, \nu_{k,60})$  com  $k = 1, 2, 3, 4$  e  $\gamma$ . Para tal, gerou-se uma cadeia de 120.000 iterações, utilizando um *burn-in* de 20.000 ciclos, com *lag* de 100, resultando em uma amostra de tamanho 1.000. A convergência dos parâmetros foi observada após período de *burn-in*.

As distribuições *a priori* foram as seguintes:  $\theta_g = (\theta_1, \theta_2, \theta_3 \text{ e } \theta_4) \sim N(0, 10^2)$  respeitando as transformações descritas na Subseção 3.3.2;  $\beta_0 = (\beta_{0,1}, \dots, \beta_{0,60}) \sim N(0, 100^2)$ ,  $\beta_1 = (\beta_{1,1}, \dots, \beta_{1,60}) \sim N(0, 100^2)$ ,  $\nu_k = (\nu_{k,1}, \dots, \nu_{k,60}) \sim N(0, 10^2)$  com  $k = 1, 2, 3, 4$  e  $\gamma \sim N(0, 100^2)$

A Figura 4.1 apresenta o gráfico da estimativa da função  $f(x)$ , o efeito espacial das câmeras na distribuição dos crimes, para duas das avenidas mais movimentadas do Centro de Belo Horizonte: Avenida Afonso Pena, onde estão instaladas as câmeras 39, 25, 34, 38 e 46; e Avenida Amazonas, que possui instaladas as câmeras de número 15, 13, 11, 34, 36 e 22. Nota-se, de forma geral, que há um aumento no número de crimes nessas avenidas. Vale ressaltar uma característica observada na maioria dos casos: nos locais em que as câmeras estão instaladas há redução do número de crimes e em pontos intermediários a duas câmeras, esse valor aumenta.




Figura 4.1: Estimativas de  $f(x)$  (média *a posteriori* e intervalo de 95% credibilidade), para a Avenida Afonso Pena e Avenida Amazonas.

Em contrapartida, quando observa-se a Figura 4.2, nota-se diminuição no número de crimes. Nessa, estão representadas a função  $f(x)$  para quatro ruas de menor movimento do Centro de Belo Horizonte: Rua dos Tupinambás onde estão as câmeras 1, 2, 3, 4, 38, 37 e 36; Rua Curitiba com as câmeras 13, 10, 5, 4, 46 e 58; Rua dos Caetés com 51, 49 e 46; e Rua dos Guaranis onde estão instaladas as câmeras 6, 2 e 51. Observa-se que a intervenção proporcionou, nessas ruas, uma redução do número de crimes. As exceções ocorrem quando essas ruas se cruzam com as avenidas citadas anteriormente. Por exemplo, ao analisar o gráfico da Rua dos Tupinambás, observa redução do número de crimes, mas esse valor se altera quando se aproxima das câmeras 38 e 36, que pertencem, respectivamente, à Avenida Afonso Pena e Amazonas.

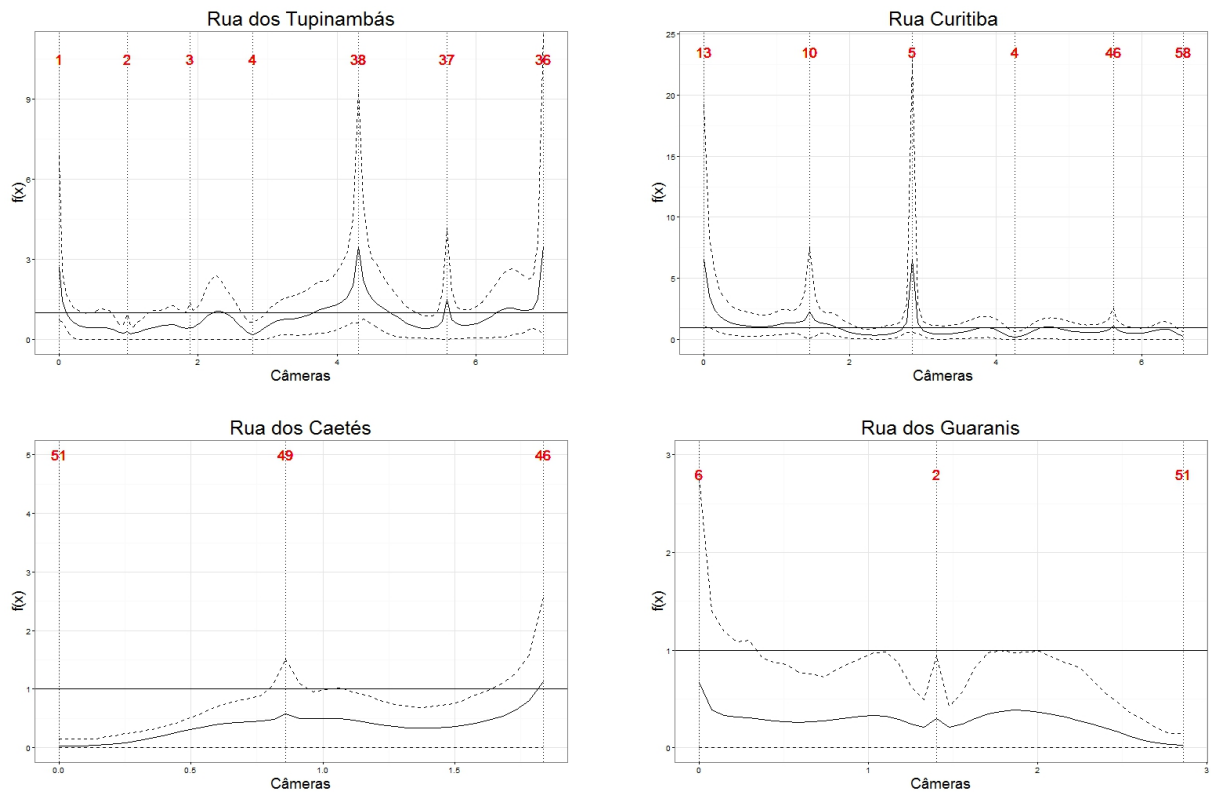


Figura 4.2: Estimativas de  $f(x)$  (média *a posteriori* e intervalo de 95% credibilidade), para a Rua dos Tupinambás, Rua Curitiba, Rua dos Caetés e Rua dos Guaranis.

Ressalta-se que as estimativas da função  $f(x)$  para as demais ruas estão apresentadas no Apêndice C.

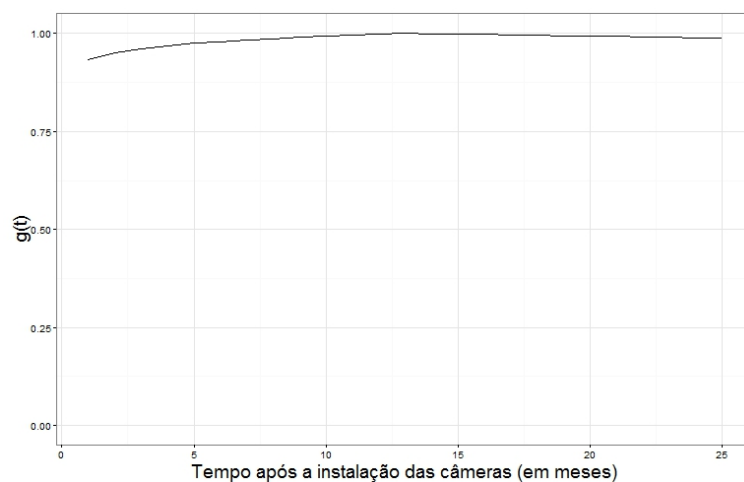


Figura 4.3: Estimativa *a posteriori* da função  $g(t)$  para as 60 câmeras.

Através da Figura 4.3 observa-se estimativa da função  $g(t)$ , que é definida como o efeito temporal das câmeras na distribuição dos crimes. Nota-se que a curva apresenta variação global mínima, ou seja, globalmente quase não se observa efeito. Ampliando a

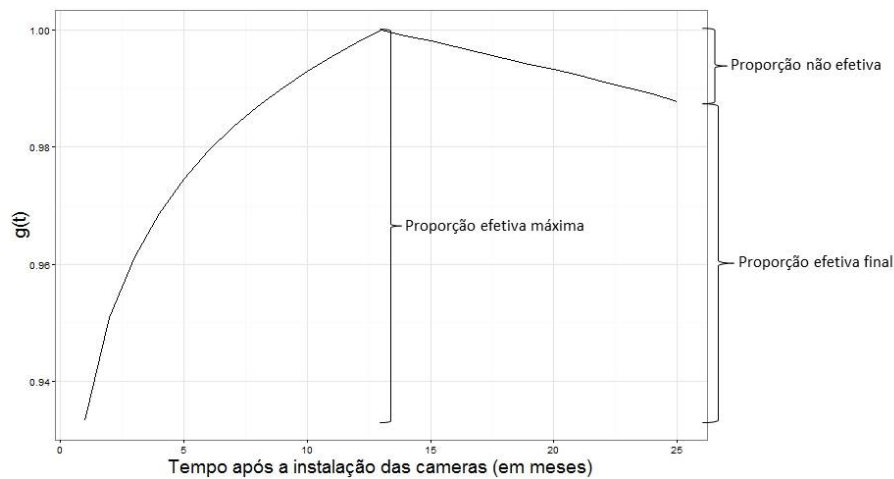


Figura 4.4: Estimativa *a posteriori* da função  $g(t)$  para as 60 câmeras.

imagem, Figura 4.4, observa-se que a curva apresenta um crescimento até o 14<sup>o</sup> mês, que representa a proporção efetiva total da intervenção na distribuição dos crimes. No 14<sup>o</sup> mês foi registrado o efeito máximo das câmeras na distribuição dos crimes. Após esse mês observa-se uma queda na curva, ou seja, a efetividade das câmeras diminui até o fim do período de estudo. Essa redução é a não-efetividade das câmeras. Dessa forma, tem-se que a efetividade final é a diferença entre a efetividade total e a não-efetividade. Portanto, pode-se dizer que globalmente, a instalação das 60 câmeras apresentou efeito muito pequeno até o 14<sup>o</sup> mês e redução desse efeito após esse período.

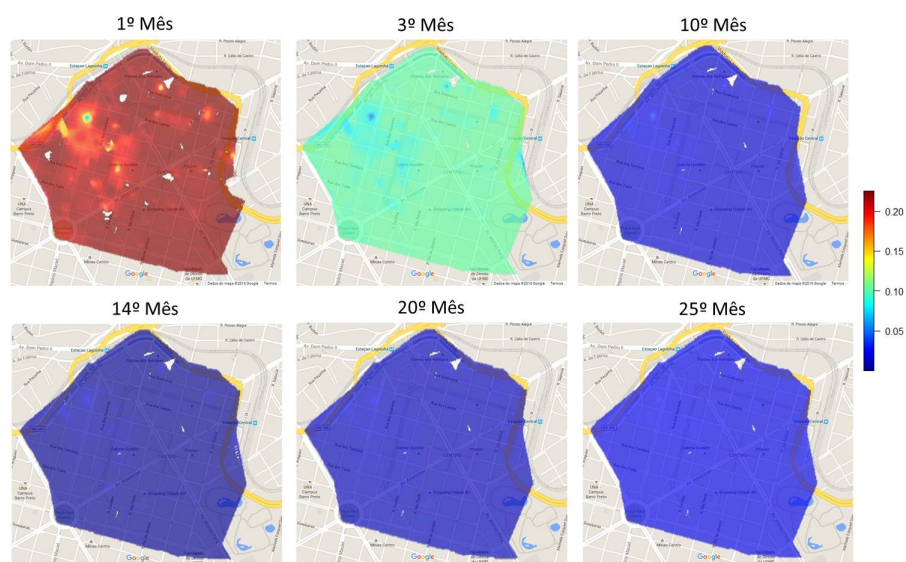


Figura 4.5: Mapas da distribuição dos crimes em seis períodos de tempo, após a instalação das câmeras.

Os mapas apresentados na Figura 4.5 mostram não só a distribuição global dos crimes ao longo do tempo, como também as regiões mais perigosas, com maior densidade de crimes. No primeiro mês, após a instalação das câmeras, a ocorrência de crimes era elevada. Entretanto, até o décimo quarto mês, período em que registra-se maior redução de crimes, ocorre diminuição gradativa da ocorrência de roubos, fato que pode ser visualizado através do terceiro e décimo mês. Após o décimo quarto mês, nota-se um novo aumento do número de crimes.

As Figuras 4.6 e 4.7 apresentam a estimativa da função  $h(x, t)$ , que representa o efeito espaço-temporal das câmeras na distribuição dos crimes, para as mesmas ruas de análise da função  $f(x)$ . Observa-se que para as duas situações, ruas mais movimentadas apresentadas na Figura 4.6 e menos movimentadas visualizadas na Figura 4.7, o comportamento de tal função foi o mesmo. Nota-se que o efeito cresce até o 13<sup>o</sup> mês e diminui no 15<sup>o</sup> mês, comprovando o resultado apresentado pela função  $g(t)$  (Figura 4.3).

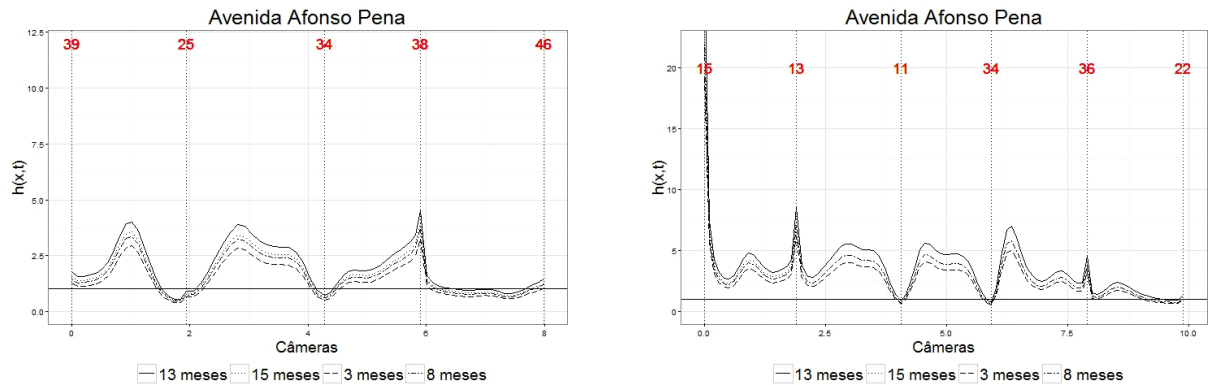


Figura 4.6: Estimativas de  $h(x, t)$ , para a Avenida Afonso Pena e Avenida Amazonas, nos tempos  $t = 3, 8, 13$  e 15 meses.

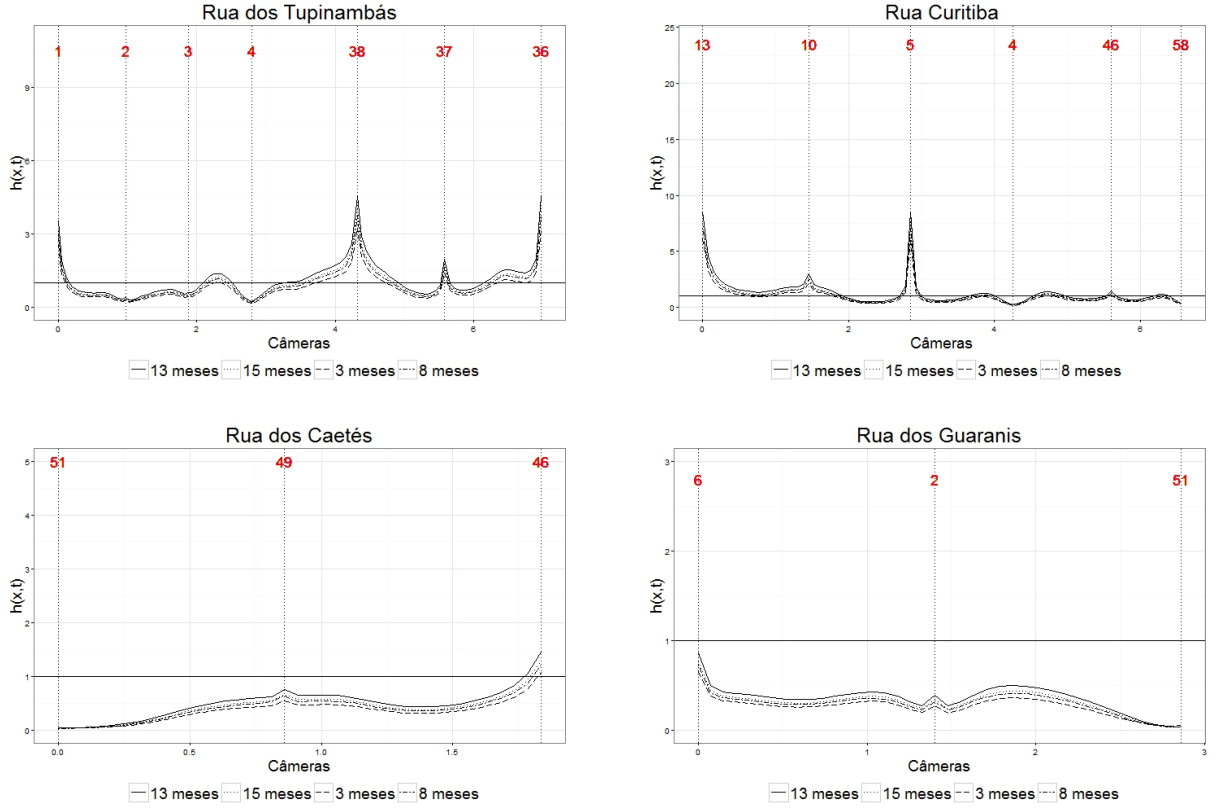


Figura 4.7: Estimativas de  $h(x, t)$ , para a Rua dos Tupinambás, Rua Curitiba, Rua dos Caetés e Rua dos Guaranis, nos tempos  $t = 3, 8, 13$  e  $15$  meses.

## 4.2 Estudo 2: Aplicação do modelo a grupos de câmeras.

Nesta seção será apresentada a aplicação do modelo considerando as câmeras divididas em grupos. Para tal, as 60 câmeras foram divididas em 6 grupos com 10 câmeras cada. Para realizar a montagem de cada grupo, considerou-se como critério, câmeras que são vizinhas no espaço. A divisão de tais grupos pode ser visualizado na Figura 4.8 e para facilitar a identificação das câmeras, a numeração apresentada na Figura 3.5 foi mantida.

Ressalta-se que cada grupo possui uma quantidade específica de crimes, pois foram considerados na análise de cada grupo apenas aqueles crimes que pertencem à região das câmeras selecionadas.

Para cada um dos seis blocos atualizou-se separadamente, via MCMC, os parâmetros  $\theta_{g,b} = (\theta_1, \theta_2, \theta_3, \theta_4)$ ,  $\beta_{0,b} = (\beta_{0,1}, \dots, \beta_{0,60})$ ,  $\beta_{1,b} = (\beta_{1,1}, \dots, \beta_{1,60})$ ,  $\nu_{k,b} = (\nu_{k,1}, \dots, \nu_{k,60})$  com  $k = 1, 2, 3, 4$  e  $\gamma$ , sendo  $b = 1, \dots, 6$ . Para tal, em cada um dos grupos, gerou-se uma cadeia de 100.000 iterações, utilizando um *burn-in* de 10.000 ciclos, com

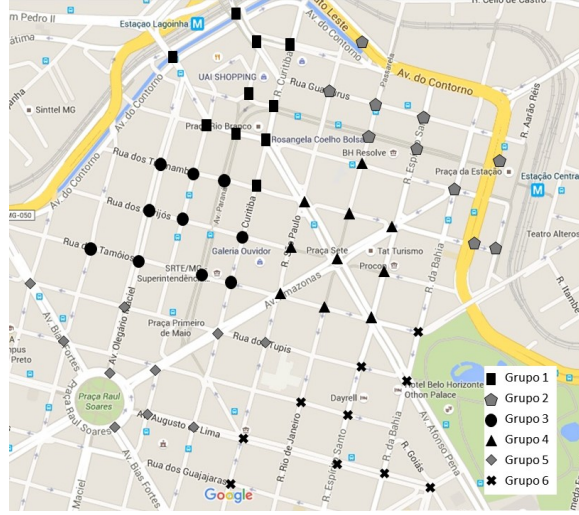


Figura 4.8: Distribuição das câmeras de circuito fechado de televisão, por grupo.

*lag* de 100, resultando em uma amostra de tamanho 900. A convergência dos parâmetros foi observada após período de *burn-in*.

As distribuições *a priori* foram as seguintes:  $\theta_{g,b} = (\theta_1, \theta_2, \theta_3 \text{ e } \theta_4) \sim N(0, 10^2)$  respeitando as transformações descritas na Subseção 3.3.2;  $\beta_{0,b} = (\beta_{0,1}, \dots, \beta_{0,60}) \sim N(0, 100^2)$ ,  $\beta_{1,b} = (\beta_{1,1}, \dots, \beta_{1,60}) \sim N(0, 100^2)$ ,  $\nu_{k,b} = (\nu_{k,1}, \dots, \nu_{k,60}) \sim N(0, 10^2)$  com  $k = 1, 2, 3, 4$  e  $\gamma \sim N(0, 100^2)$ , sendo  $b = 1, \dots, 6$ .

Ressalta-se que as análises de todos os grupos foram realizadas. Mas, por similaridade dos grupos 1 e 3, e pelos grupos 2, 4, 5 e 6 também serem semelhantes, optou-se por apresentar nas Seções 4.2.1 e 4.2.2 apenas as análises dos grupos 1 e 4 respectivamente. O estudo dos demais grupos encontram-se no Apêndice D.

### 4.2.1 Análise das estimativas obtidas pelos dados do Grupo 01

Para compor esse grupo, foram selecionadas as câmeras de número 4, 46, 47, 48, 49, 50, 51, 52, 54, e 58. Nessa região foram contabilizados 5.217 crimes, sendo 4.059 antes da instalação das câmeras e 1.158 após a intervenção. A Figura 4.9 apresenta a distribuição dos crimes que ocorreram após a instalação das câmeras, por mês. Observa-se que os dois primeiros meses contabilizaram a maior quantidade de crimes, após esse período nota-se que a quantidade de crimes diminuiu, mas não de forma constante.

A Tabela 4.1 apresenta a quantidade de crimes, pós intervenção, distribuída em intervalos de meses. Observa-se que a maior quantidade de crimes ocorreu do 1º ao 5º




Figura 4.9: Número de crimes, por mês, após a instalação das câmeras para o grupo 01.

mês, sendo esse valor exatamente o dobro da quantidade de crimes observada no último intervalo, que engloba do 21<sup>o</sup> ao 25<sup>o</sup> mês.

Tabela 4.1: Distribuição da quantidade de crimes do grupo 01, após a instalação das câmeras, em intervalos de meses.

Distribuição dos meses	Quantidade de Crimes	%
1 <sup>o</sup> ao 5 <sup>o</sup>	344	29,7
6 <sup>o</sup> ao 10 <sup>o</sup>	229	19,8
11 <sup>o</sup> ao 15 <sup>o</sup>	198	17,1
16 <sup>o</sup> ao 20 <sup>o</sup>	215	18,6
21 <sup>o</sup> ao 25 <sup>o</sup>	172	14,8
<b>Total</b>	<b>1.158</b>	<b>100</b>

Observa-se através da Figura 4.10 a estimativa da função  $f(x)$  para duas ruas nas quais as câmeras do grupo 01 foram instaladas. Tratam-se de duas ruas de menor movimento, Rua Curitiba e Rua dos Caetés. Observa-se que houve redução do número de crimes mas, com aumento desse valor em pontos próximos a determinadas câmeras. As câmeras, perto das quais se observa crescimento do número de crimes, são aquelas localizadas em regiões mais movimentadas, como por exemplo, a câmera 46 que está localizada no cruzamento dessas ruas com a Avenida Afonso Pena.

A Figura 4.11 apresenta a estimativa da função  $g(t)$  para o grupo em análise. Observa-se que a instalação das câmeras nessa região foi efetiva, atingindo efeito máximo




Figura 4.10: Estimativas de  $f(x)$  (média *a posteriori* e intervalo de 95% credibilidade) para a Rua Curitiba e Rua dos Caetés, para o grupo 01.

aproximadamente dois meses após a intervenção e permanecendo, sem ocorrer redução, até o final do período de análise.




Figura 4.11: Estimativa *a posteriori* da função  $g(t)$ , para o grupo 01 das câmeras.

Apresenta-se pela Figura 4.12 a estimativa da função  $h(x, t)$ , para o grupo 01 no tempos 1, 2, 3 e 6 meses após a instalação das câmeras. Observa-se que não houve diferença na distribuição dos crimes ao longo do tempo, o que confirma o apresentado na Figura 4.11, o efeito das câmeras ocorreu nos primeiros meses de instalação.

Ressalta-se que, por apresentar comportamento semelhante ao grupo 01, a análise do grupo 03 se encontra no Apêndice D.

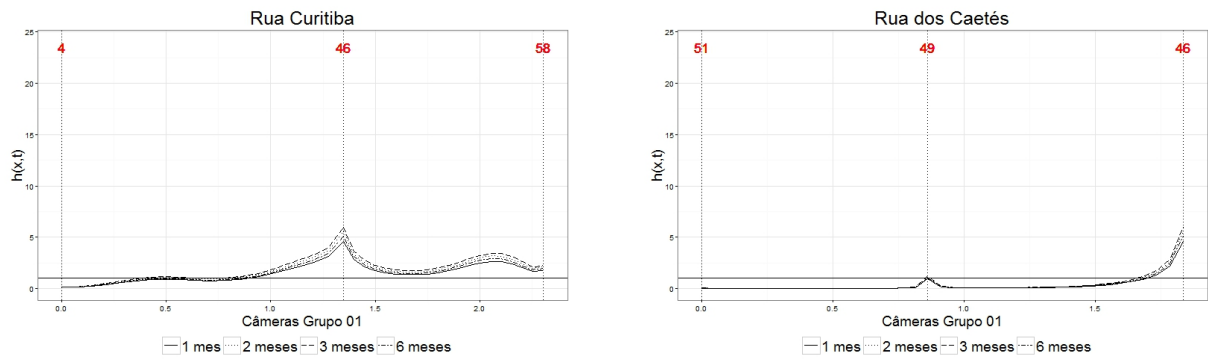


Figura 4.12: Estimativas de  $h(x, t)$  para a Rua Curitiba e Rua dos Caetés, para o grupo 01, nos tempos  $t = 1, 2, 3$  e 6 meses.

#### 4.2.2 Análise das estimativas obtidas pelos dados do Grupo 04

O grupo 04 corresponde à seleção de câmeras que pertencem à região de ruas mais movimentadas do Centro de Belo Horizonte, que compõem a Praça Sete de Setembro. Tais possuem a seguinte numeração: 11, 25, 26, 27, 34, 35, 36, 37, 38 e 45. Em tal região foram contabilizados 3.319 crimes, sendo 2.380 antes e 939 após a intervenção.

A Figura 4.13 apresenta a distribuição dos crimes que ocorreram após a instalação das câmeras, por mês. Observa-se que a maioria dos crimes estão agrupados do 1<sup>o</sup> ao 11<sup>o</sup> mês, com destaque ao 4<sup>o</sup> mês onde se observa queda relativamente acentuada.

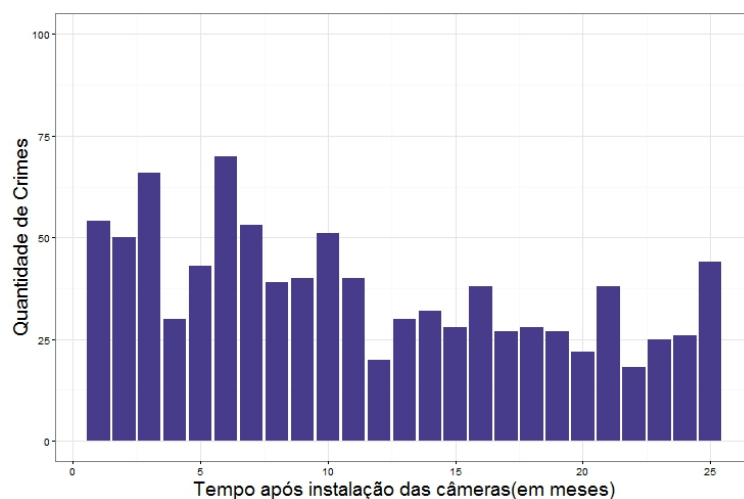


Figura 4.13: Número de crimes, por mês, após a instalação das câmeras, para o grupo 04.

Afirmando o que foi apresentado na Figura 4.13, a Tabela 4.2 mostra que, aproximadamente 53% dos crimes que foram registradas pelas câmeras pertencentes ao

Tabela 4.2: Distribuição da quantidade de crimes do grupo 04, após a instalação das câmeras, em intervalos de meses.

Distribuição dos meses	Quantidade de Crimes	%
1 <sup>o</sup> ao 5 <sup>o</sup>	243	25,9
6 <sup>o</sup> ao 10 <sup>o</sup>	253	26,9
11 <sup>o</sup> ao 15 <sup>o</sup>	150	16,0
16 <sup>o</sup> ao 20 <sup>o</sup>	142	15,1
21 <sup>o</sup> ao 25 <sup>o</sup>	151	16,1
<b>Total</b>	<b>939</b>	<b>100</b>

grupo 4, ocorreram do 1<sup>o</sup> ao 10<sup>o</sup> mês. Nos demais intervalos, a quantidade de crimes é bem homogênea.

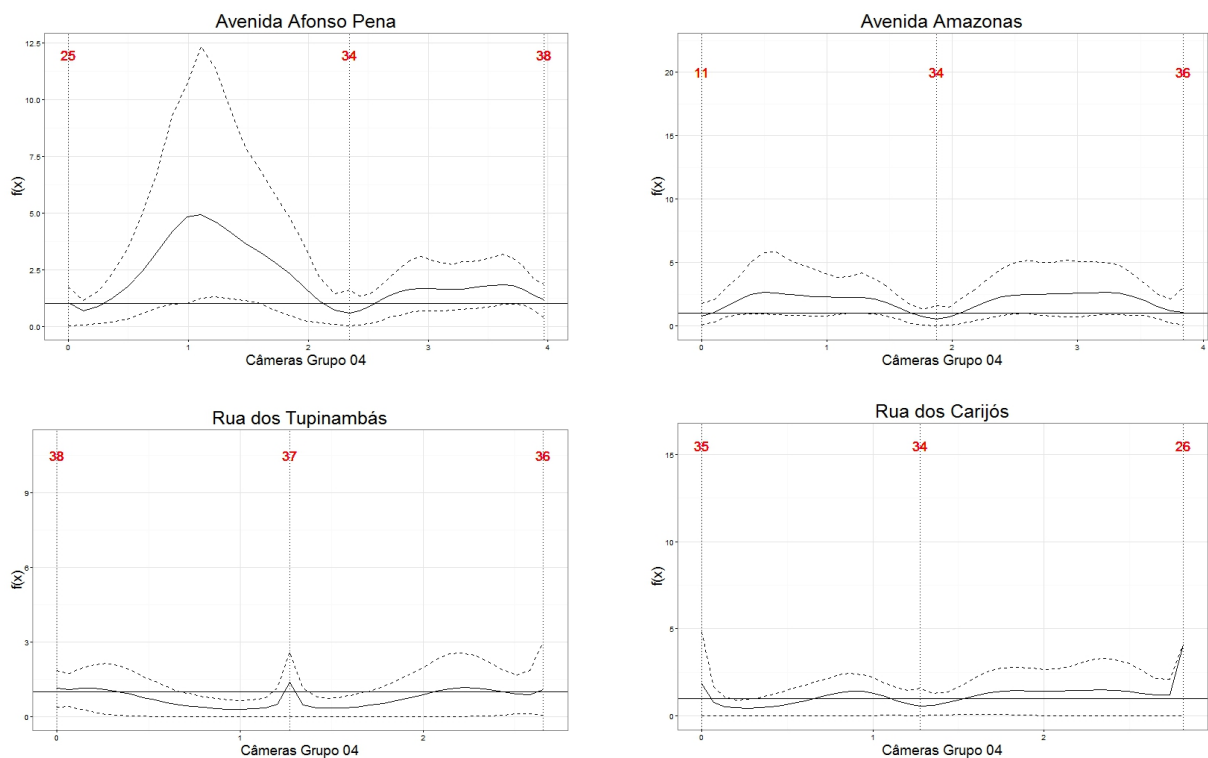


Figura 4.14: Estimativas de  $f(x)$  (média *a posteriori* e intervalo de 95% credibilidade) para a Avenida Afonso Pena, Avenida Amazonas, Rua dos Tupinambás e Rua dos Carijós, para o grupo 04.

Através da Figura 4.14 observa-se o efeito espacial na distribuição dos crimes. Nas Avenidas de maior movimento, Afonso Pena e Amazonas, nota-se crescimento

na quantidades de crimes. Já para as demais Ruas, Tupinambás e Carijós, registra-se diminuição nos crimes, como esperado.

A Figura 4.15 apresenta a estimativa da função  $g(t)$  para o grupo em análise. Observa-se que a instalação das câmeras nessa região foi efetiva, com efeito máximo no 18<sup>o</sup> mês pós intervenção, com ligeira queda até o 19<sup>o</sup> e permanecendo, sem ocorrer decaimento, até o final do período de análise.




Figura 4.15: Estimativa *a posteriori* da função  $g(t)$ , para o grupo 04 das câmeras.

O efeito das câmeras, pertencentes ao grupo 04, na distribuição espacial original dos eventos, está representado na Figura 4.16. Nota-se que após o 18<sup>o</sup> mês, período que foi observado o efeito máximo da intervenção, o efeito praticamente se torna inexistente.

Ressalta-se que, por apresentar comportamento semelhante ao grupo 04, a análise do grupo 02, 05 e 06 encontram-se no Apêndice D.

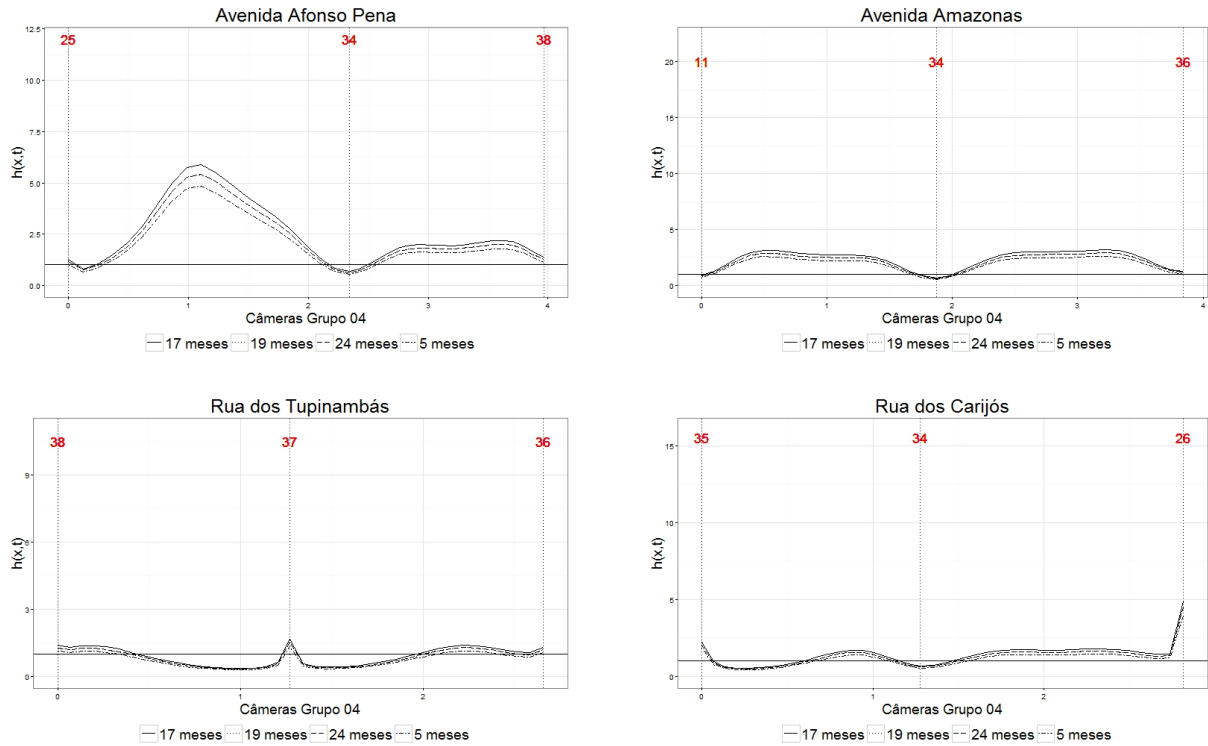


Figura 4.16: Estimativas de  $h(x, t)$  para a Avenida Afonso Pena, Avenida Amazonas, Rua dos Tupinambás e Rua dos Carijós, para o grupo 04, nos tempos  $t = 5, 17, 19$  e  $24$  meses.

### 4.3 Estudo 3: Aplicação do modelo a cada câmera individualmente.

Nesta seção será apresentada a aplicação do modelo a cada câmera separadamente, resultando dessa forma em 60 funções temporais. Cada câmera será referenciada pela numeração que foi utilizada no decorrer de todo o estudo, apresentada na Figura 3.5. Ressalta-se que, como cada câmera registrou uma quantidade específica de crimes, somente os respectivos eventos capturados por cada uma foi utilizada na análise da mesma.

Modificou-se a atualização do vetor de parâmetros  $\theta_g$ . Os parâmetros tempo decorrido até atingir o pico máximo da intervenção e proporção não-efetiva da intervenção,  $\theta_1$  e  $\theta_3$  respectivamente, foram atualizados individualmente para cada câmera. Enquanto os parâmetros  $\theta_2$  e  $\theta_4$  foram atualizados utilizando-se as informações de todas as câmeras conjuntamente. O embasamento para tal decisão está nas análises realizadas anteriormente, onde observou-se que, tanto na análise das 60 câmeras, quanto no estudos dos blocos, a forma da função  $g(t)$  é aparentemente a mesma.

Os demais foram estimados conjuntamente pelas informações das 60 câmeras. Portanto, atualizou-se via MCMC, os parâmetros  $\boldsymbol{\theta}_g = (\theta_{1,c}, \theta_2, \theta_{3,c}, \theta_4)$  com  $c = 1, \dots, 60$ ,  $\boldsymbol{\beta}_0 = (\beta_{0,1}, \dots, \beta_{0,60})$ ,  $\boldsymbol{\beta}_1 = (\beta_{1,1}, \dots, \beta_{1,60})$ ,  $\boldsymbol{\nu}_k = (\nu_{k,1}, \dots, \nu_{k,60})$  com  $k = 1, 2, 3, 4$  e  $\gamma$ . Para tal, gerou-se uma cadeia de 100.000 iterações, utilizando um *burn-in* de 10.000 ciclos, com *lag* de 100, resultando em uma amostra de tamanho 900. A convergência dos parâmetros foi observada após período de *burn-in*.

As distribuições *a priori* foram as seguintes:  $\boldsymbol{\theta}_g = (\theta_{1,c}, \theta_2, \theta_{3,c}, \theta_4) \sim N(0, 10^2)$ , com  $c = 1, \dots, 60$ , respeitando as transformações descritas na Subseção 3.3.2;  $\boldsymbol{\beta}_0 = (\beta_{0,1}, \dots, \beta_{0,60}) \sim N(0, 100^2)$ ,  $\boldsymbol{\beta}_1 = (\beta_{1,1}, \dots, \beta_{1,60}) \sim N(0, 100^2)$ ,  $\boldsymbol{\nu}_k = (\nu_{k,1}, \dots, \nu_{k,60}) \sim N(0, 10^2)$  com  $k = 1, 2, 3, 4$  e  $\gamma \sim N(0, 100^2)$ .

Para realizar a análise foram escolhidas seis câmeras separando-as em três cenários, aquelas câmeras que foram efetivas, reduzindo o número de crimes na região em que se encontram instaladas; as câmeras que não tiveram efeito, ou seja, a quantidade de crimes antes e após a intervenção permaneceu aproximadamente constante; e aquelas que não foram efetivas, a quantidade de crimes após a instalação das câmeras foi maior ao registrado antes da instalação. No Apêndice E estão apresentadas as funções  $g(t)$  para as outras 54 câmeras.

A Figura 4.17 apresenta a função  $g(t)$  para as câmeras 3 e 59. Observa-se que a proporção efetiva máxima é alcançada no 13<sup>o</sup> e 14<sup>o</sup>, para a câmera 3 e 59 respectivamente, e que após esses meses as suas funções apresentam redução. Observa-se que a proporção de efetividade final é positiva, sinalizando que as câmeras foram efetivas. Relacionando esse resultado ao apresentado na Figura 3.6 observa-se que essas duas câmeras apresentam razões menores que 1, indicando que a quantidade de crimes foi menor após a instalação quando comparado ao valor observado antes da instalação das câmeras, evidenciando o resultado encontrado.

Os resultados apresentados na Figura 4.18 mostram o oposto ao encontrado na Figura 4.17. Observa-se que a função  $g(t)$ , para as câmeras 15 e 17, apresenta crescimento, atingindo o efeito máximo nos meses 13 e 14, respectivamente. Porém, após esse período, nota-se queda rápida na curva da função, resultando em uma proporção de efetividade final negativa, evidenciando que essas duas câmeras não foram efetivas. Através da Figura 3.6 também observamos esse fato, essas duas câmeras apresentam razões maiores que




Figura 4.17: Estimativa *a posteriori* da função  $g(t)$  para as câmeras 3 e 59.




Figura 4.18: Estimativa *a posteriori* da função  $g(t)$  para as câmeras 15 e 17.

1, indicando que a ocorrência de crimes depois da intervenção foi maior que antes da instalação das câmeras.

A Figura 4.19 apresenta a função  $g(t)$  para as câmeras 34 e 44. Para essas duas câmeras observa-se que a proporção efetiva total (crescimento da curva) é praticamente o mesmo valor da proporção não efetiva da intervenção (queda da curva), informando dessa forma que essas duas câmeras não possuíram efeito. Tal fato também pode ser observado pela Figura 3.6, onde a proporção de crimes depois e antes da intervenção é próximo de zero para as duas câmeras, confirmando que essas não modificaram o espaço onde foram instaladas.

Através das Figuras apresentadas anteriormente, observa-se que cada curva possui determinada característica, com efeitos máximos em meses distintos e decaimento diferenciado. Portanto, esse resultado evidencia a hipótese de que o efeito das câmeras varia no tempo.




Figura 4.19: Estimativa *a posteriori* da função  $g(t)$  para as câmeras 34 e 44.

## 5 Considerações Finais e Trabalhos Futuros

### 5.1 Considerações Finais

Nesse trabalho foi proposto um modelo espaço-temporal para um problema de intervenção complexo, os roubos contra a pessoa no Centro de Belo Horizonte. Modelamos a distribuição espacial de eventos, em qualquer tempo  $t$ , como a mistura de duas densidades: a distribuição espacial dos eventos antes e a distribuição daqueles que ocorreram após a instalação de câmeras de circuito fechado de televisão. Para desenvolver o estudo, nos apoiamos na flexibilidade da modelagem não-paramétrica que permitiu incorporar à análise a topologia das ruas.

Diante dos resultados encontrados, de forma geral, observamos que os crimes foram reduzidos em algumas partes da região em estudo em detrimento do aumento em outras. Ficou claro diante dos resultados, que a redução se apresentava ativamente em regiões onde a circulação de pessoas acontecia de forma menos intensa. Em contrapartida, o aumento do número de roubos aconteceu em regiões de alto movimento de pedestres, principalmente no cruzamento entre a Avenida Afonso Pena e Avenida Amazonas e na sua vizinhança, um dos pontos de maior movimento da cidade de Belo Horizonte. Entretanto, em áreas onde a proporção de crimes tem aumentado, a taxa se apresenta menor nas imediações de uma câmera.

Os resultados dos estudos mostram que o efeito das câmeras na distribuição espacial dos eventos, ao longo do tempo, é diferente nas diversas áreas, dentro da região de estudo. Foi possível observar tal fato, através dos cenários que foram contruídos ao longo do texto. Observou-se que o comportamento da função temporal, seja na função global, nos grupo ou para cada câmera individualmente, não é equivalente, variando dessa forma no espaço.

Segundo Brown (2010), o efeito global da câmera ao longo do tempo pode representar apenas um deslocamento dos crimes para outra região, em vez de ser uma redução no número de crimes. Isso confirma o que foi apresentado nessa dissertação. Outro estudo que pode ser citado, e que também afirma parte da nossa conclusão, é o

realizado por Rodrigues et al. (2010). Nele, apesar de modelar os eventos apenas na esfera espacial, mostra que o efeito das câmeras provoca uma disseminação dos crimes e não uma redução quantitativa.

O modelo desenvolvido nessa dissertação, pode ser aplicado com sucesso em outras áreas científicas. Por exemplo, a análise de processos pontuais com intervenção de fontes pontuais em epidemiologia, onde o objetivo é investigar a possível elevação do risco da doença em torno de uma ou mais potenciais fontes pontuais.

## 5.2 Trabalhos Futuros

Pelo exposto anteriormente, existe um crescente interesse em modelagem espaço-temporal para solução e/ou sugestões de melhoria de questões nas mais diversas áreas do conhecimento. Assim, o interesse está em algumas extensões da forma:

- Propor modelos espaço-temporais mais gerais, motivados por aplicações. Naturalmente também serão propostas metodologias Bayesianas para se fazer inferência dos mesmos;
- Propor uma modelagem não-paramétrica para a função  $g(t)$  para tornar o modelo mais robusto;
- Incluir covariáveis no modelo;
- Utilizar idéias de Aprendizado de Máquina para classificar a ocorrência de crime em cada tempo, fazendo um modelo competidor ao proposto;
- Realizar estudo com outros tipos de crimes, como por exemplo crimes contra residência, visando verificar se as câmeras são efetivas para esse tipo de evento.

## A Apêndice

Neste apêndice estão os *scripts* utilizados para comparar o tempo de compilação do R, C e Rcpp(C++).

- **Script R**

```
myprodR <- function(x, y) {
  dd1 <- dim(x)
  dd2 <- dim(y)
  if (dd1[2] != dd2[1])
    stop("Invalid dimensions!")
  res <- matrix(0, dd1[1], dd2[2])
  for (i in 1:dd1[1])
    for (j in 1:dd2[2])
      res[i,j] <- sum(x[i,]*y[,j])
  return(res)
}
```

- **Script C**

```
#include<R.h>
#include <math.h>

void myprod(double *x, double *y, int *dims, double *res) {
  int i, j, k, id1=0, id2=0, id3=0;
  for (j=0; j<dims[2]; j++) {
    for (i=0; i<dims[0]; i++) {
      id3 = 0;
      for (k=0; k<dims[1]; k++) {
res[id1] += x[id3+i] * y[id2+k];
      id3 += dims[0];
    }
  }
}
```

```
        id1++;
    }
    id2 += dims[1];
}
}
```

- *Script Rcpp(C++)*

```
#include <Rcpp.h>
#include <cmath>
#include <Rmath.h>
#include <iostream>
using namespace Rcpp;
using namespace std;
RNGScope scope;

//Multiplicação de Matrizes
// [[Rcpp::export]]
NumericMatrix myprodRcpp(NumericMatrix x, NumericMatrix y, int dim1,
                          int dim2, int dim3){
    NumericMatrix out(dim1, dim3);
    for (int i=0; i < dim1; i++){
        for (int j=0; j < dim3; j++){
            for (int k=0; k < dim2; k++){
                out(i,j) += (x(i,k)*y(k,j));
            }
        }
    }
    return(out);
}
```

## B Apêndice

Nesse apêndice estão descritas as distribuições condicionais completas.

- **Condicional Completa para  $\theta_{1aux}$ ,  $\theta_{2aux}$ ,  $\theta_{3aux}$  e  $\theta_{4aux}$**

$$\pi(\theta_{iaux} | \boldsymbol{\theta}_l, \boldsymbol{\beta}_0, \boldsymbol{\beta}_1, \gamma, \boldsymbol{\nu}, \mathbf{Y}, \mathbf{X}, \boldsymbol{\eta}, t) \propto \prod_x \left\{ \prod_t \left[ \frac{h(x, t) \eta_1(t)}{\eta_0 + \sum_{j=1}^T h(x, j) \eta_1(j)} \right]^{y_{x,t}} \right\} \times \exp \left\{ -\frac{1}{2\sigma_{\theta_{iaux}}^2} (\theta_{iaux} - \mu_{\theta_{iaux}})^2 \right\}.$$

$$\text{Sendo: } i = 1, 2, 3 \text{ e } 4 \quad \text{e} \quad \boldsymbol{\theta}_l = \begin{cases} (\theta_2, \theta_3, \theta_4), & \text{se } i = 1 \\ (\theta_1, \theta_3, \theta_4), & \text{se } i = 2 \\ (\theta_1, \theta_2, \theta_4), & \text{se } i = 3 \\ (\theta_1, \theta_2, \theta_3), & \text{se } i = 4 \end{cases}.$$

Como  $\theta_i$  é uma função de  $\theta_{iaux}$ ,  $\theta_i = r(\theta_{iaux})$ , e, de acordo com (3.4), a distribuição condicional completa para  $\theta_{iaux}$  assume,

1. Para  $t_0 \leq t < \theta_1$ :

– Para  $\theta_{1aux}$ :

$$\pi(\theta_{1aux} | \theta_2, \theta_3, \theta_4, \boldsymbol{\beta}_0, \boldsymbol{\beta}_1, \gamma, \boldsymbol{\nu}, \mathbf{Y}, \mathbf{X}, \boldsymbol{\eta}, t) \propto \exp \left\{ -\frac{1}{2\sigma_{\theta_{1aux}}^2} (\theta_{1aux} - \mu_{\theta_{1aux}})^2 \right\} \times \prod_x \left\{ \prod_t \left[ \frac{\left( 1 - \left( \left( \frac{t-t_0}{r(\theta_{1aux})} \right)^{\theta_2} \right) (1 - f(x)) \right) \eta_1(t)}{\eta_0 + \sum_{j=1}^T \left( 1 - \left( \left( \frac{j-t_0}{r(\theta_{1aux})} \right)^{\theta_2} \right) (1 - f(x)) \right) \eta_1(j)} \right]^{y_{x,t}} \right\}.$$

– Para  $\theta_{2aux}$ :

$$\pi(\theta_{2aux} | \theta_1, \theta_3, \theta_4, \boldsymbol{\beta}_0, \boldsymbol{\beta}_1, \gamma, \boldsymbol{\nu}, \mathbf{Y}, \mathbf{X}, \boldsymbol{\eta}, t) \propto \exp \left\{ -\frac{1}{2\sigma_{\theta_{2aux}}^2} (\theta_{2aux} - \mu_{\theta_{2aux}})^2 \right\} \times \prod_x \left\{ \prod_t \left[ \frac{\left( 1 - \left( \left( \frac{t-t_0}{\theta_1} \right)^{r(\theta_{2aux})} \right) (1 - f(x)) \right) \eta_1(t)}{\eta_0 + \sum_{j=1}^T \left( 1 - \left( \left( \frac{j-t_0}{\theta_1} \right)^{r(\theta_{2aux})} \right) (1 - f(x)) \right) \eta_1(j)} \right]^{y_{x,t}} \right\}.$$

– Para  $\theta_{3aux}$ :

$$\pi(\theta_{3aux}|\theta_1, \theta_2, \theta_4, \boldsymbol{\beta}_0, \boldsymbol{\beta}_1, \gamma, \boldsymbol{\nu}, \mathbf{Y}, \mathbf{X}, \boldsymbol{\eta}, t) \propto \exp \left\{ -\frac{1}{2\sigma_{\theta_{3aux}}^2} (\theta_{3aux} - \mu_{\theta_{3aux}})^2 \right\}$$

– Para  $\theta_{4aux}$ :

$$\pi(\theta_{4aux}|\theta_1, \theta_2, \theta_3, \boldsymbol{\beta}_0, \boldsymbol{\beta}_1, \gamma, \boldsymbol{\nu}, \mathbf{Y}, \mathbf{X}, \boldsymbol{\eta}, t) \propto \exp \left\{ -\frac{1}{2\sigma_{\theta_{4aux}}^2} (\theta_{4aux} - \mu_{\theta_{4aux}})^2 \right\}$$

2. Para  $t \geq \theta_1$ :

– Para  $\theta_{1aux}$

$$\begin{aligned} & \pi(\theta_{1aux}|\theta_2, \theta_3, \theta_4, \boldsymbol{\beta}_0, \boldsymbol{\beta}_1, \gamma, \boldsymbol{\nu}, \mathbf{Y}, \mathbf{X}, \boldsymbol{\eta}, t) \propto \exp \left\{ -\frac{1}{2\sigma_{\theta_{1aux}}^2} (\theta_{1aux} - \mu_{\theta_{1aux}})^2 \right\} \times \\ & \times \prod_x \left\{ \prod_t \left[ \frac{\left( 1 - \left( 1 - \theta_3 \left( 1 - \left( \frac{(T-t)}{T-r(\theta_{1aux})} \right)^{\theta_4} \right) \right) (1 - f(x)) \right) \eta_1(t)}{\eta_0 + \sum_{j=1}^T \left( 1 - \left( 1 - \theta_3 \left( 1 - \left( \frac{(T-j)}{T-r(\theta_{1aux})} \right)^{\theta_4} \right) \right) (1 - f(x)) \right) \eta_1(j)} \right]^{y_{x,t}} \right\}. \end{aligned}$$

– Para  $\theta_{2aux}$ :

$$\pi(\theta_{2aux}|\theta_1, \theta_3, \theta_4, \boldsymbol{\beta}_0, \boldsymbol{\beta}_1, \gamma, \boldsymbol{\nu}, \mathbf{Y}, \mathbf{X}, \boldsymbol{\eta}, t) \propto \exp \left\{ -\frac{1}{2\sigma_{\theta_{2aux}}^2} (\theta_{2aux} - \mu_{\theta_{2aux}})^2 \right\}$$

– Para  $\theta_{3aux}$ :

$$\begin{aligned} & \pi(\theta_{3aux}|\theta_1, \theta_2, \theta_4, \boldsymbol{\beta}_0, \boldsymbol{\beta}_1, \gamma, \boldsymbol{\nu}, \mathbf{Y}, \mathbf{X}, \boldsymbol{\eta}, t) \propto \exp \left\{ -\frac{1}{2\sigma_{\theta_{3aux}}^2} (\theta_{3aux} - \mu_{\theta_{3aux}})^2 \right\} \times \\ & \times \prod_x \left\{ \prod_t \left[ \frac{\left( 1 - \left( 1 - r(\theta_{3aux}) \left( 1 - \left( \frac{(T-t)}{T-\theta_1} \right)^{\theta_4} \right) \right) (1 - f(x)) \right) \eta_1(t)}{\eta_0 + \sum_{j=1}^T \left( 1 - \left( 1 - r(\theta_{3aux}) \left( 1 - \left( \frac{(T-j)}{T-\theta_1} \right)^{\theta_4} \right) \right) (1 - f(x)) \right) \eta_1(j)} \right]^{y_{x,t}} \right\}. \end{aligned}$$

– Para  $\theta_{4aux}$ :

$$\begin{aligned} & \pi(\theta_{4aux}|\theta_1, \theta_2, \theta_3, \boldsymbol{\beta}_0, \boldsymbol{\beta}_1, \gamma, \boldsymbol{\nu}, \mathbf{Y}, \mathbf{X}, \boldsymbol{\eta}, t) \propto \exp \left\{ -\frac{1}{2\sigma_{\theta_{4aux}}^2} (\theta_{4aux} - \mu_{\theta_{4aux}})^2 \right\} \times \\ & \times \prod_x \left\{ \prod_t \left[ \frac{\left( 1 - \left( 1 - \theta_3 \left( 1 - \left( \frac{(T-t)}{T-\theta_1} \right)^{r(\theta_{4aux})} \right) \right) (1 - f(x)) \right) \eta_1(t)}{\eta_0 + \sum_{j=1}^T \left( 1 - \left( 1 - \theta_3 \left( 1 - \left( \frac{(T-j)}{T-\theta_1} \right)^{r(\theta_{4aux})} \right) \right) (1 - f(x)) \right) \eta_1(j)} \right]^{y_{x,t}} \right\}. \end{aligned}$$

• **Condicional Completa**  $\beta_0, \beta_1, \gamma$  e  $\nu$

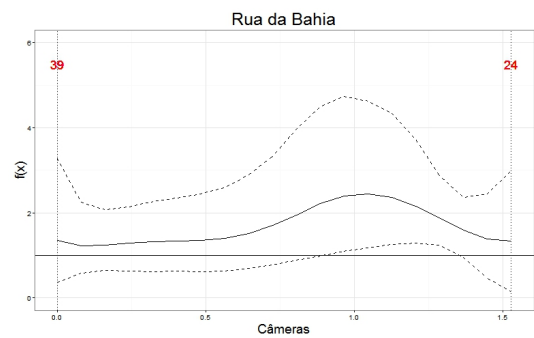
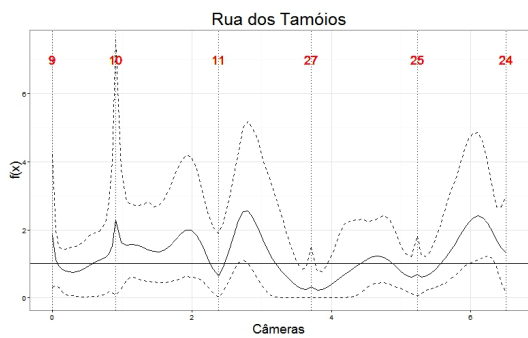
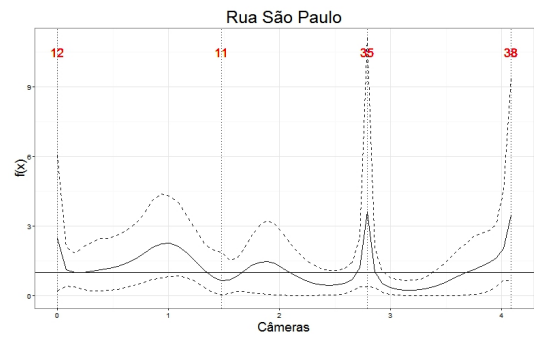
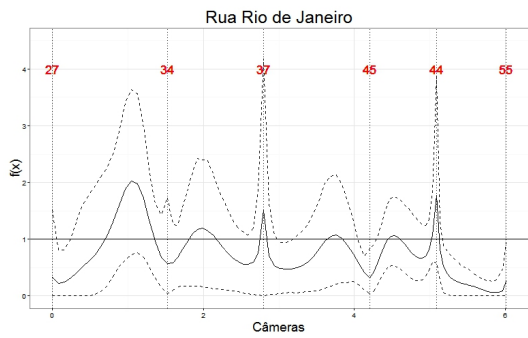


$$\begin{aligned} \pi(\Upsilon|\theta_1, \theta_2, \theta_3, \theta_4, \delta, \mathbf{Y}, \mathbf{X}, \boldsymbol{\mu}, t) &\propto \prod_x \left\{ \frac{(\sum_t y_{x,t})!}{\prod_t y_{x,t}!} \prod_t \left[ \frac{h(x,t)\mu(t)}{m + \sum_{j=1}^T h(x,j)\mu(j)} \right]^{y_{x,t}} \right\} \times \\ &\times \exp \left\{ -\frac{1}{2\sigma_\Upsilon^2} (\Upsilon - \mu_\Upsilon)^2 \right\} \end{aligned} \quad (\text{B.1})$$

$$\text{Onde: } \delta = \begin{cases} \beta_1, \gamma, \nu, & \text{se } \Upsilon = \beta_0 \\ \beta_0, \gamma, \nu, & \text{se } \Upsilon = \beta_1 \\ \beta_0, \beta_1, \nu, & \text{se } \Upsilon = \gamma \\ \beta_0, \beta_1, \gamma, & \text{se } \Upsilon = \nu \end{cases} \quad \text{e}$$

$$\begin{aligned} f(x) &= \gamma + \log [w_{i(x)}] + \boldsymbol{\beta}_{0,i(x)} + \boldsymbol{\beta}_{1,i(x)}(\|x - x_{0,i(x)}\|) + \sum_{k=1}^K \nu_{k,i(x)} \left| \|x - x_{0,i(x)}\| - z_k \right|^3 + \\ &+ \log [w_{j(x)}] + \boldsymbol{\beta}_{0,j(x)} + \boldsymbol{\beta}_{1,j(x)}(\|x - x_{0,j(x)}\|) + \sum_{k=1}^K \nu_{k,j(x)} \left| \|x - x_{0,j(x)}\| - z_k \right|^3. \end{aligned}$$

## C Apêndice

Apresenta-se aqui, as demais estimativas para a função  $f(x)$ , do modelo aplicado a todas as câmeras.



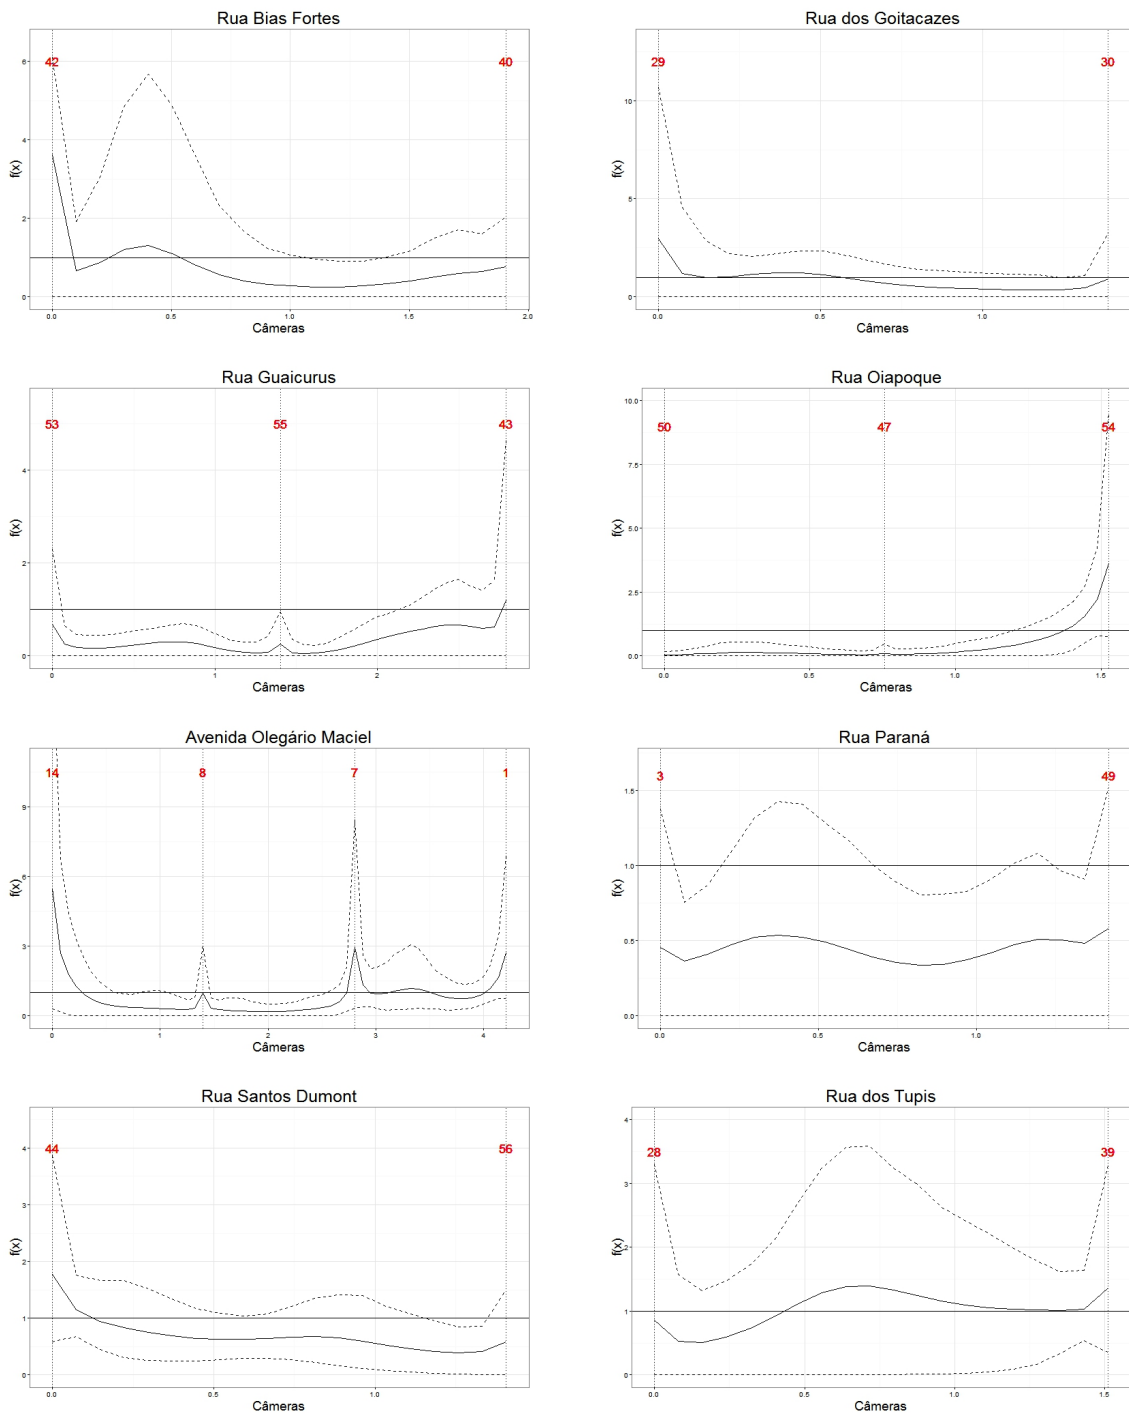


Figura C.1: Estimativas de  $f(x)$  (média *a posteriori* e intervalo de 90% credibilidade), para a Rua dos Carijós, Rua Espírito Santo, Rua Rio de Janeiro, Rua São Paulo, Rua dos Tamoios, Rua da Bahia, Rua Bias Fortes, Rua dos Goitacazes, Rua Guaicurus, Rua Oiapoque, Avenida Olegário Maciel, Rua Paraná, Rua Santos Dumont e Rua dos Tupis.

## D Apêndice

### D.0.1 Análise das estimativas obtidas pelos dados do Grupo 02

As câmeras 22, 23, 33, 43, 44, 53, 55, 56, 57 e 59 compõem tal grupo. O total de delitos dessa região é igual a 4.865, sendo 3.542 antes da instalação das câmeras e 1.323 pós intervenção.




Figura D.1: Número de crimes, por mês, após a instalação das câmeras, para o grupo 02.

A quantidade de crimes que ocorreram após a intervenção estão especificados, por mês, através da Figura D.1. Nota-se que a maior quantidade de crimes, pós intervenção, foi observada no terceiro mês após a instalação das câmeras, ressaltando que houve um aumento expressivo nessa quantidade no 25º mês de análise.

Confirmando os valores apresentados pela Figura D.1, a Tabela D.1, mostra que a maior quantidade de crimes ocorreu do 1º ao 5º, apresentando ligeira queda entre o 6º e o 20º mês, e aumento discreto no intervalo compreendido entre 21º a 25º mês.

A Figura D.2 apresenta a estimativa da função  $f(x)$  para duas ruas pertencentes à região do grupo 02. Nota-se que houve redução do número de crimes na Rua dos Guaicurus e Rua Santos Dumont, ambas de menor movimento.

Através da análise da estimativa da função  $g(t)$  para o grupo 2, apresentada na Figura D.3, observa-se que o comportamento da função foi bem divergente daquela

Tabela D.1: Distribuição da quantidade de crimes do grupo 02, após a instalação das câmeras, em intervalos de meses.

Distribuição dos meses	Quantidade de Crimes	%
1 <sup>o</sup> ao 5 <sup>o</sup>	401	30,3
6 <sup>o</sup> ao 10 <sup>o</sup>	289	21,8
11 <sup>o</sup> ao 15 <sup>o</sup>	204	15,5
16 <sup>o</sup> ao 20 <sup>o</sup>	200	15,1
21 <sup>o</sup> ao 25 <sup>o</sup>	229	17,3
<b>Total</b>	<b>1.323</b>	<b>100</b>

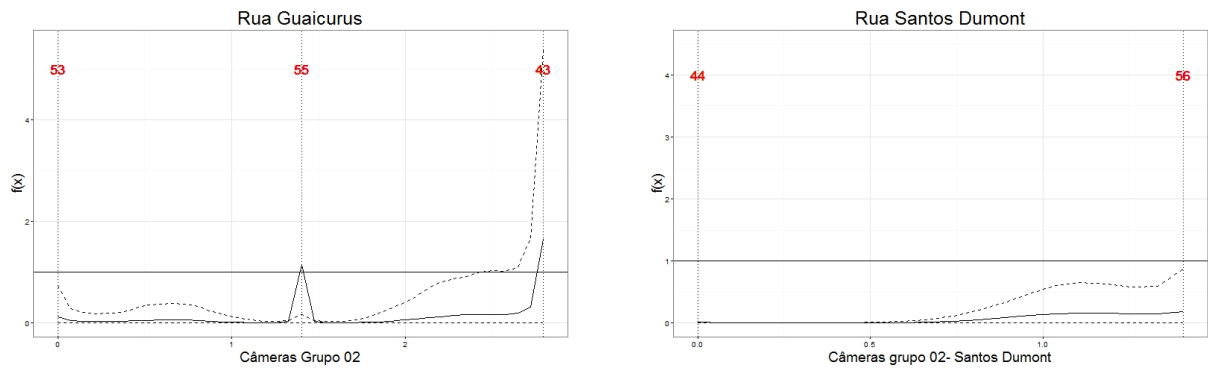


Figura D.2: Estimativas de  $f(x)$  (média *a posteriori* e intervalo de 95% credibilidade) para a Rua Guaicurus e Rua Santos Dumont, para o grupo 02.




Figura D.3: Estimativa *a posteriori* da função  $g(t)$ , para o grupo 02 das câmeras.

apresentada pelo grupo 01. Nota-se que o efeito máximo da intervenção foi atingido aproximadamente no 12<sup>o</sup> mês após a instalação das câmeras. Nota-se que esse efeito decaiu até o 13<sup>o</sup> mês, permanecendo constante após esse período.

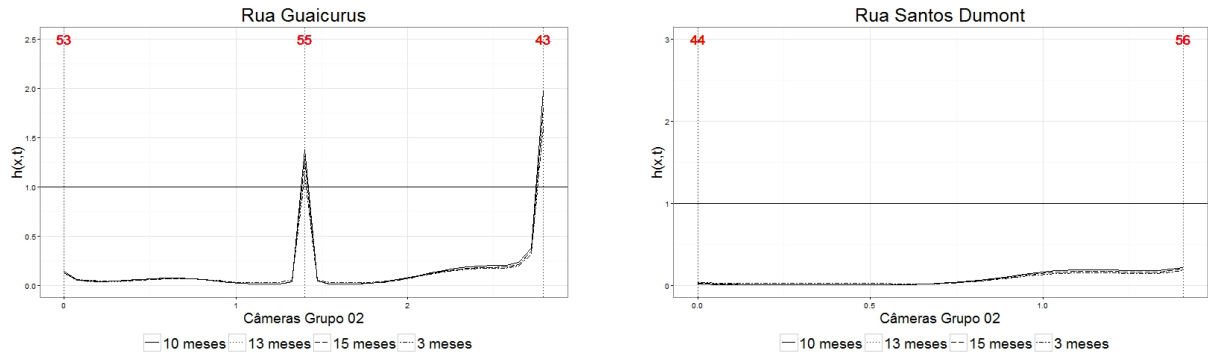


Figura D.4: Estimativas de  $h(x, t)$  para a Rua Guaicurus e Rua dos Santos Dumont, para o grupo 02, nos tempos  $t = 3, 10, 13$  e  $15$  meses.

A Figura D.4 mostra o efeito das câmeras através da distribuição espacial dos eventos. Observa-se que para as duas ruas apresentadas, Guaicurus e Santos Dumont, o efeito praticamente não existe.

## D.0.2 Análise das estimativas obtidas pelos dados do Grupo 03

Para formar esse grupo, as câmeras selecionadas foram 1, 2, 3, 5, 6, 7, 8, 9, 10, 41. O total de registros de crime contra a pessoa, na região de instalação dessas câmeras, antes da intervenção, foi igual a 1.870, após a intervenção foi igual 621, totalizando 2.491 crimes. A Figura D.5 apresenta a distribuição da quantidade de crimes, por mês, após a instalação das câmeras, para o grupo 03. Observa-se que a quantidade de crimes no primeiro mês, após a instalação, das câmeras é praticamente o mesmo da quantidade observada no último mês de análise.

Através da Tabela D.2, é possível notar que a quantidade de crimes registrada nos intervalos de meses, não são muito discrepantes entre si. Vale destacar que a menor quantidade de crimes, foi observada entre 16<sup>o</sup> e 20<sup>o</sup> mês pós intervenção.

A estimativa do efeito espacial das câmeras do grupo 03,  $f(x)$ , na Rua Tupinambás e Avenida Olegário Maciel, está descrita na Figura D.6. Nota-se, como já observado para ruas menos movimentadas, que o número de crimes foi reduzido, com pequena elevação nas proximidades de algumas câmeras.




Figura D.5: Número de crimes, por mês, após a instalação das câmeras, para o grupo 03.

Tabela D.2: Distribuição da quantidade de crimes do grupo 03, após a instalação das câmeras, em intervalos de meses.

Distribuição dos meses	Quantidade de Crimes	%
1 <sup>o</sup> ao 5 <sup>o</sup>	153	24,6
6 <sup>o</sup> ao 10 <sup>o</sup>	142	22,8
11 <sup>o</sup> ao 15 <sup>o</sup>	114	18,4
16 <sup>o</sup> ao 20 <sup>o</sup>	98	15,8
21 <sup>o</sup> ao 25 <sup>o</sup>	114	18,4
<b>Total</b>	<b>621</b>	<b>100</b>

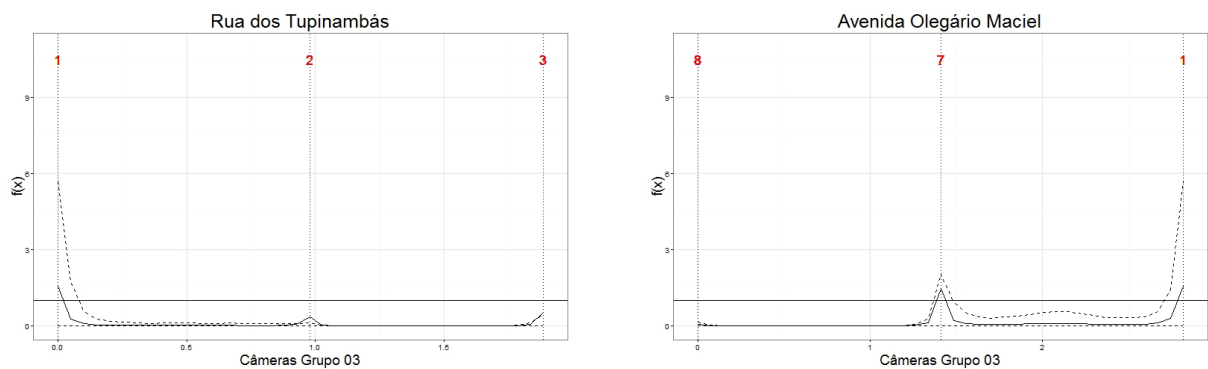


Figura D.6: Estimativas de  $f(x)$  (média *a posteriori* e intervalo de 95% credibilidade) para a Rua dos Tupinambás e Avenida Olegário Maciel, para o grupo 03.

A estimativa da função  $g(t)$ , apresentada na Figura D.7, mostra que o efeito máximo da instalação das câmeras ocorreu por volta do 3<sup>o</sup> mês após a instalação das

câmeras de circuito fechado de televisão. Observa-se que a intervenção nessa região foi efetiva, e a efetividade máxima pode ser constatada até o fim do período de análise.




Figura D.7: Estimativa *a posteriori* da função  $g(t)$ , para o grupo 03 das câmeras.




Figura D.8: Estimativas de  $h(x, t)$  para a Rua Tupinambás e Avenida Olegário Maciel, para o grupo 03, nos tempos  $t = 1, 4, 8$  e 12 meses.

A Figura D.8 apresenta a estimativa da função  $h(x, t)$ , para o grupo 03 no tempos 1, 4, 8 e 12 meses após a instalação das câmeras. Como o efeito máximo das câmeras ocorreu nos primeiros meses após a intervenção e permaneceu constante, a diferença de crimes após o 3<sup>o</sup> mês é mínima.

### D.0.3 Análise das estimativas obtidas pelos dados do Grupo 05

Para compor esse grupo, foram selecionadas as câmeras de número 12, 13, 14, 15, 16, 17, 19, 20, 40 e 42. Nessa região foram contabilizados 2.530 crimes, sendo 1.723

antes da instalação das câmeras e 807 após a intervenção. A Figura D.9 apresenta a distribuição dos crimes que ocorreram após a instalação das câmeras, por mês. Observa-se que o número de delitos registrados no primeiro mês é aproximadamente igual àqueles registrados no terceiro e último mês de apuração. Nota-se que no segundo mês de instalação das câmeras há uma queda na quantidade de crimes, voltando a crescer consideravelmente no terceiro mês.




Figura D.9: Número de crimes, por mês, após a instalação das câmeras, para o grupo 05.

A Tabela D.3 mostra que, para o grupo em análise, a maior quantidade de crimes ocorreu do 1<sup>o</sup> ao 10<sup>o</sup>, e a menor entre o 16<sup>o</sup> e 20<sup>o</sup> após a instalação das câmeras.

Tabela D.3: Distribuição da quantidade de crimes do grupo 05, após a instalação das câmeras, em intervalos de meses.

Distribuição dos meses	Quantidade de Crimes	%
1 <sup>o</sup> ao 5 <sup>o</sup>	208	25,7
6 <sup>o</sup> ao 10 <sup>o</sup>	199	24,7
11 <sup>o</sup> ao 15 <sup>o</sup>	140	17,3
16 <sup>o</sup> ao 20 <sup>o</sup>	111	13,8
21 <sup>o</sup> ao 25 <sup>o</sup>	149	18,5
<b>Total</b>	<b>807</b>	<b>100</b>

O efeito espacial na distribuição dos crimes das câmeras pertencentes ao grupo 05, está apresentado na Figura D.10. Nota-se que ocorreu aumento dos crimes na Avenida

Amazonas e redução na Avenida Augusto de Lima, evidenciando a suposição de que os crimes se transferiram para região de maior movimento.

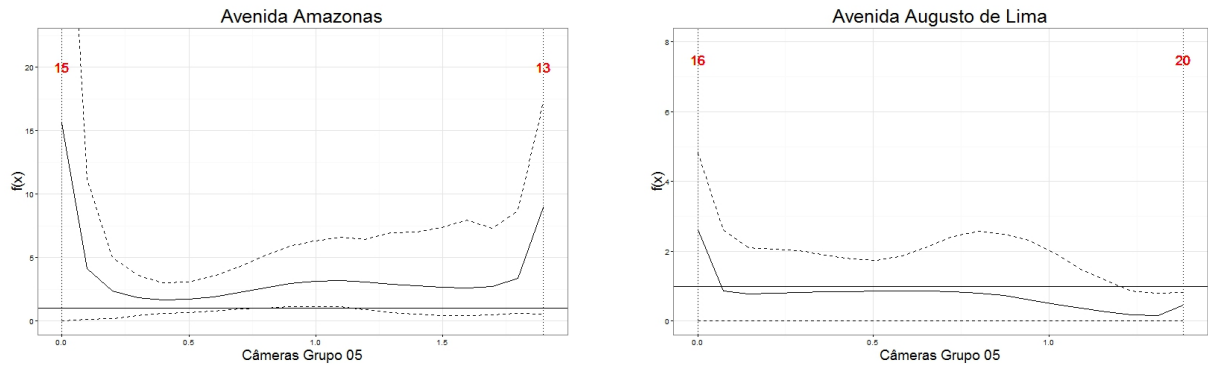


Figura D.10: Estimativas de  $f(x)$  (média *a posteriori* e intervalo de 95% credibilidade) para a Avenida Amazonas e Avenida Augusto de Lima, para o grupo 05.

A Figura D.11 apresenta a estimativa da função  $g(t)$  para o grupo em análise. Observa-se que a instalação das câmeras nessa região foi efetiva, atingindo efeito máximo aproximadamente no 13<sup>o</sup> mês após a intervenção, apresentando redução desse efeito após esse mês e mantendo-se constante após o 14<sup>o</sup> mês.




Figura D.11: Estimativa *a posteriori* da função  $g(t)$ , para o grupo 05 das câmeras.

Os gráficos apresentados na Figura D.12 confirmam que, após o 13<sup>o</sup> mês, o efeito das câmeras na distribuição dos crimes ao longo do tempo praticamente se extingue.

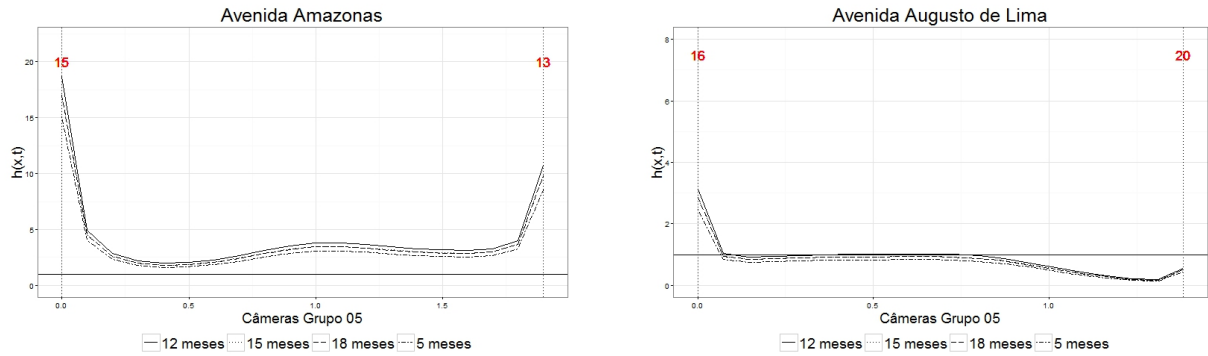


Figura D.12: Estimativas de  $h(x,t)$  para a Avenida Amazonas e Avenida Augusto de Lima, para o grupo 05, nos tempos  $t = 5, 12, 15$  e  $18$  meses.

#### D.0.4 Análise das estimativas obtidas pelos dados do Grupo 06

As câmeras 18, 21, 24, 28, 29, 30, 31, 32, 39 e 60 compõem tal grupo. O total de delitos dessa região é igual a 2.850, sendo 1.998 antes da instalação das câmeras e 852 pós intervenção.




Figura D.13: Número de crimes, por mês, após a instalação das câmeras, para o grupo 06.

A quantidade crimes que ocorreram após a intervenção estão especificados, por mês, através da Figura D.13. Nota-se que a maior quantidade de crimes, pós intervenção, foi observada no 7<sup>o</sup> e 10<sup>o</sup> mês pós instalação.

Através da Tabela D.4 é possível observar que, aproximadamente 56% dos crimes registrados pelas câmeras desse grupo, ocorreram entre o 1<sup>o</sup> e 10<sup>o</sup> mês. Nos demais meses não se observa valores discrepantes para os intervalos.

Tabela D.4: Distribuição da quantidade de crimes do grupo 06, após a instalação das câmeras, em intervalos de meses.

Distribuição dos meses	Quantidade de Crimes	%
1 <sup>o</sup> ao 5 <sup>o</sup>	228	26,8
6 <sup>o</sup> ao 10 <sup>o</sup>	245	28,8
11 <sup>o</sup> ao 15 <sup>o</sup>	115	13,5
16 <sup>o</sup> ao 20 <sup>o</sup>	135	15,8
21 <sup>o</sup> ao 25 <sup>o</sup>	129	15,1
<b>Total</b>	<b>852</b>	<b>100</b>

A Figura D.14 apresenta a estimativa da função  $f(x)$  para duas ruas pertencentes à região do grupo 06. Nota-se que, de forma geral, houve redução do número de crimes na Avenida Augusto de Lima e Rua dos Goitacazes, ambas de menor movimento.

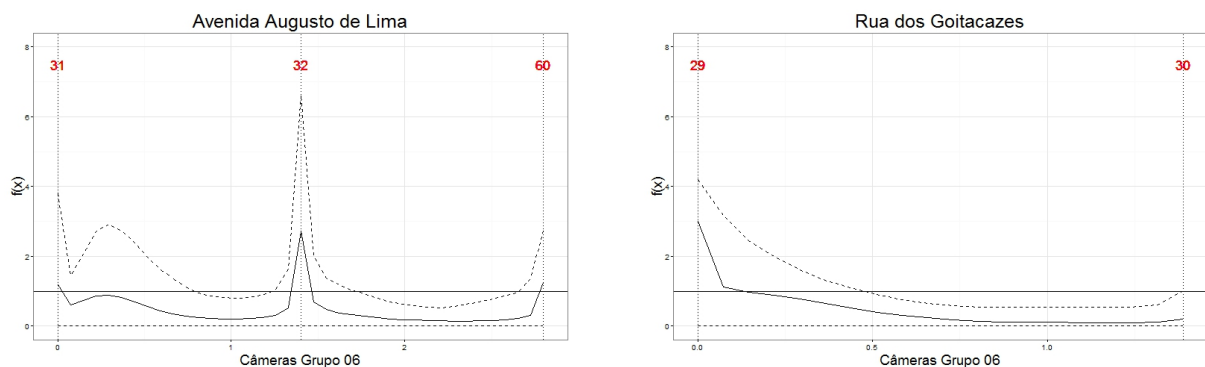


Figura D.14: Estimativas de  $f(x)$  (média *a posteriori* e intervalo de 95% credibilidade) para a Avenida Augusto de Lima e Rua dos Goitacazes, para o grupo 06.

Através da análise da estimativa da função  $g(t)$  para o grupo 6, apresentada na Figura D.15, observa-se que o efeito máximo da intervenção foi atingido aproximadamente no 14<sup>o</sup> mês após a instalação das câmeras. Nota-se que esse efeito decaiu até o 15<sup>o</sup> mês, permanecendo constante após esse período.

O efeito das câmeras, pertencentes ao grupo 06, na distribuição espacial original dos eventos, está representado na Figura D.16. Nota-se que após o 14<sup>o</sup> mês, período que foi observado o efeito máximo da intervenção, o efeito praticamente se torna inexistente.




Figura D.15: Estimativa *a posteriori* da função  $g(t)$ , para o grupo 06 das câmeras.

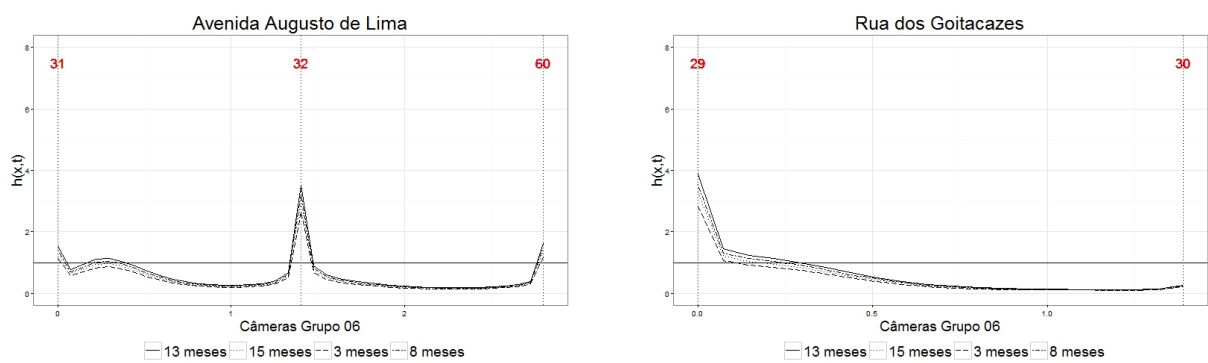


Figura D.16: Estimativas de  $h(x,t)$  para a Avenida Augusto de Lima e Rua dos Goitacazes, para o grupo 06, nos tempos  $t = 3, 8, 13$  e  $15$  meses.

## E Apêndice

Nesse Apêndice estão apresentadas as funções do tempo, referente à análise de cada câmera separadamente.

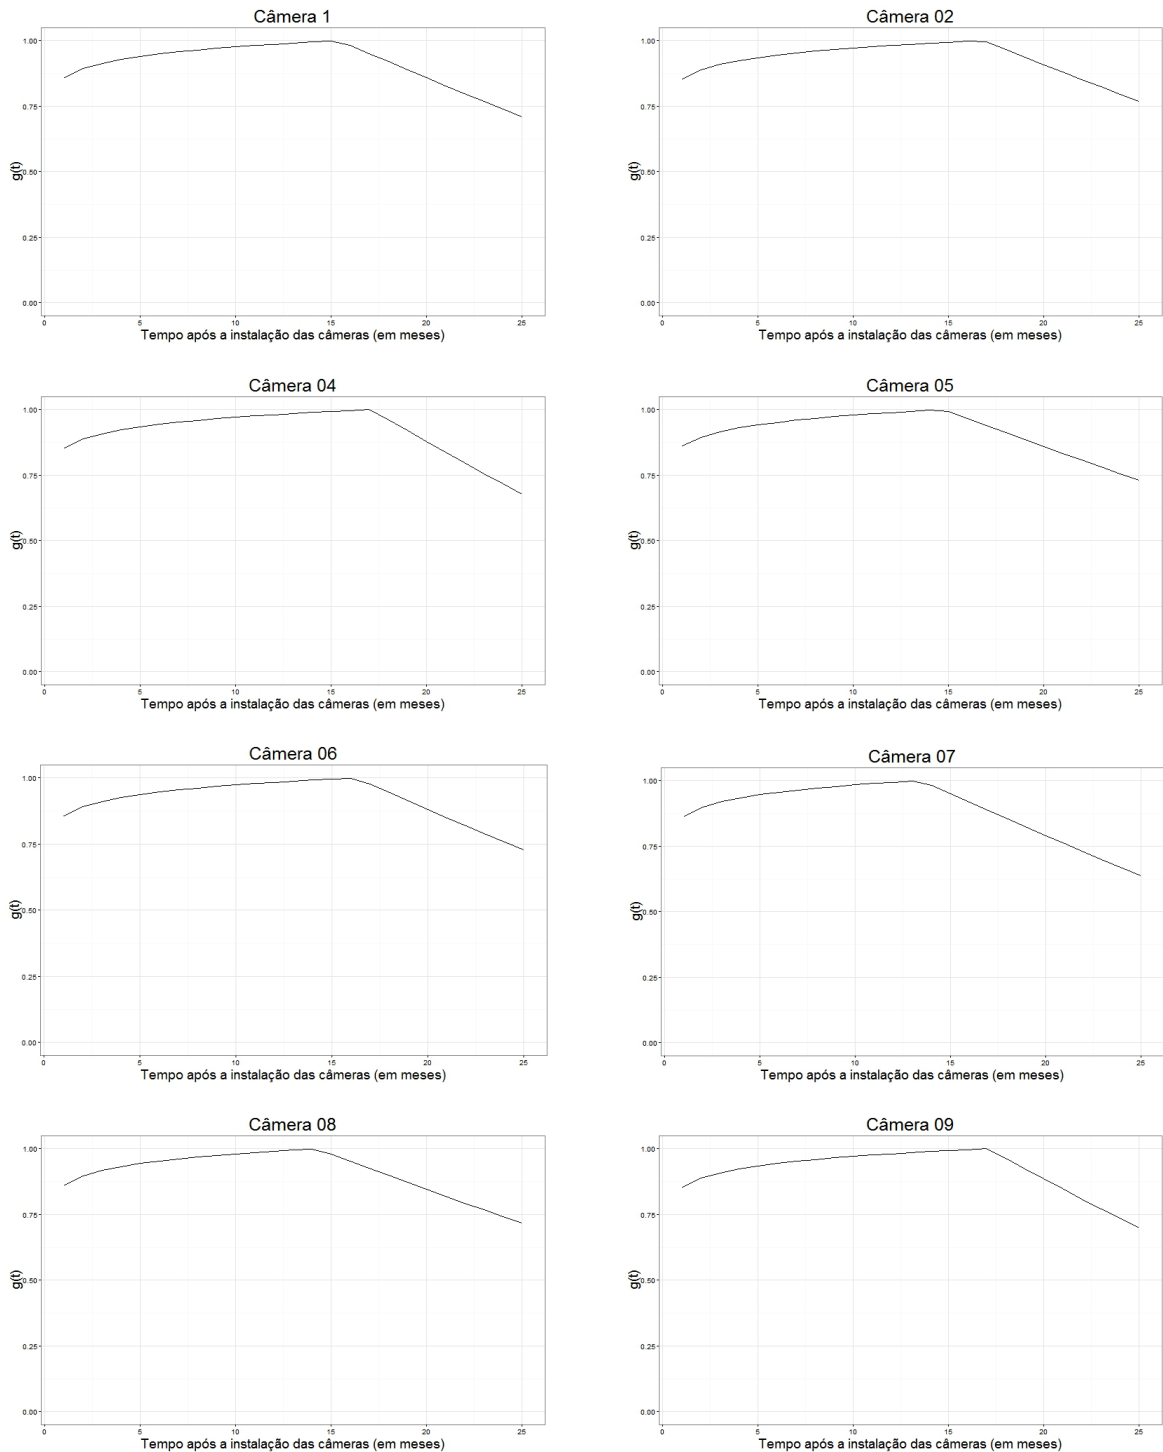


Figura E.1: Estimativa *a posteriori* da função  $g(t)$  para as câmeras 1, 2, 4, 5, 6, 7, 8 e 9.

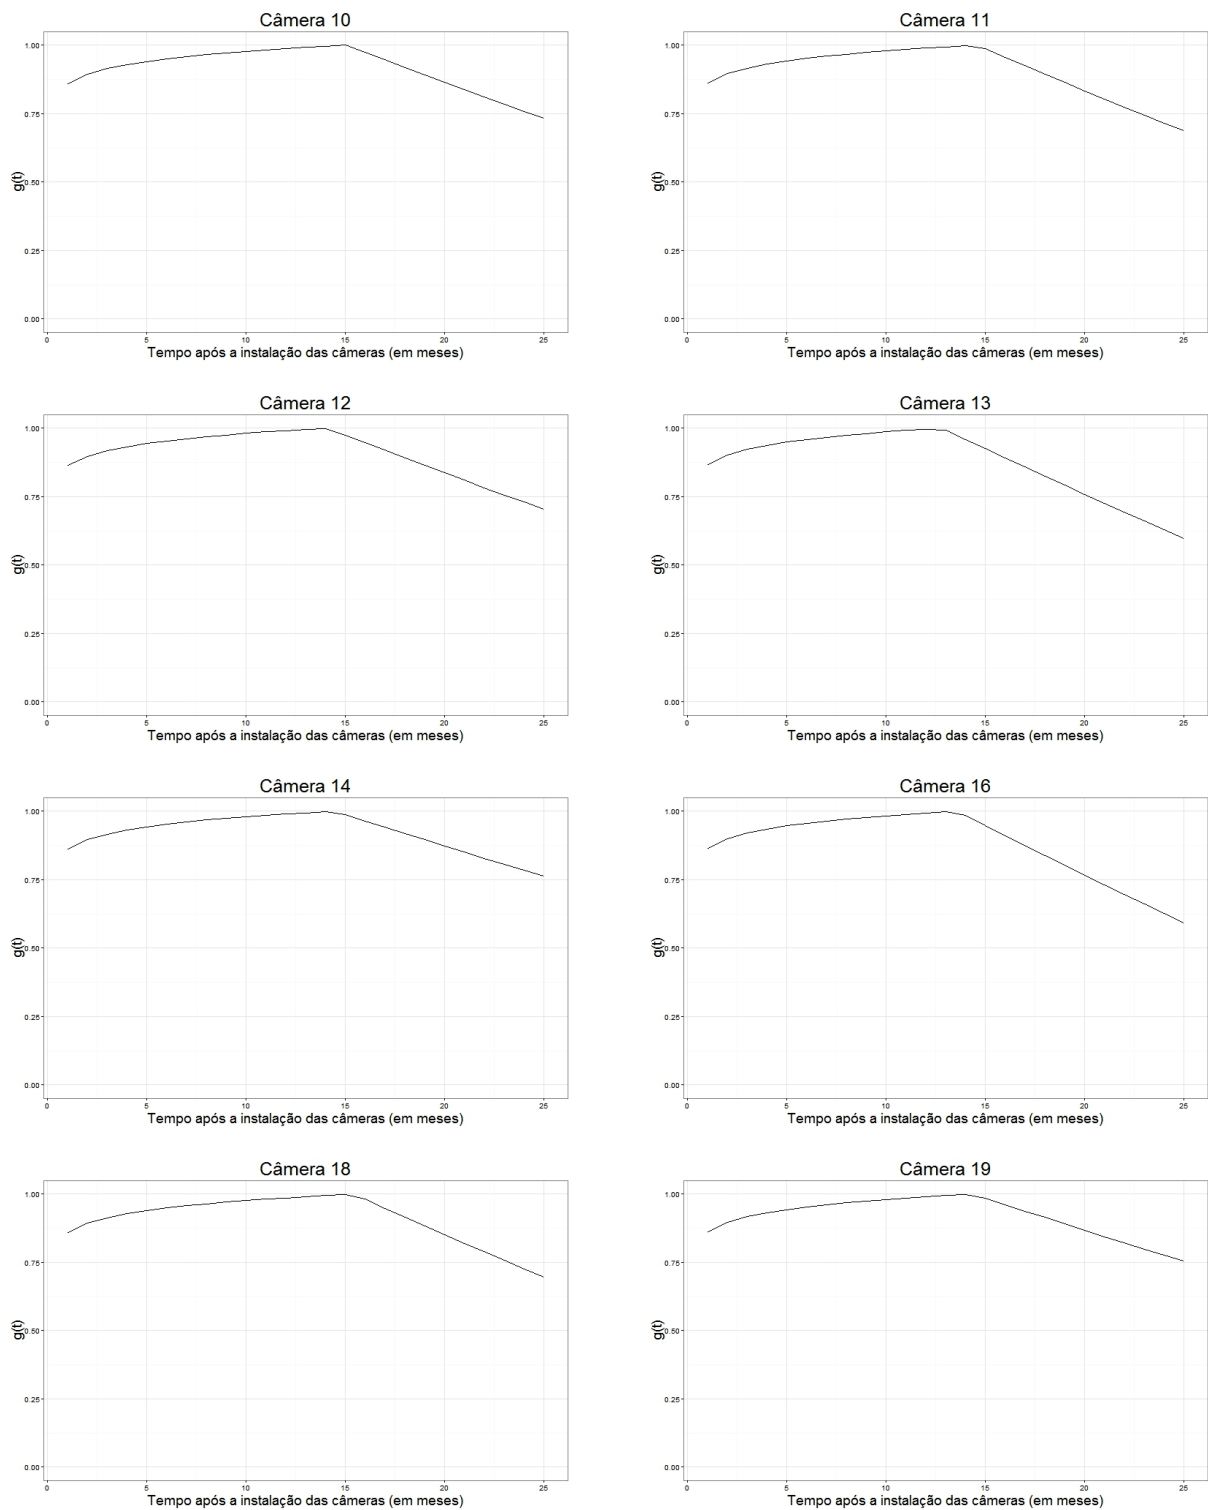


Figura E.2: Estimativa *a posteriori* da função  $g(t)$  para as câmeras 10, 11, 12, 13, 14, 16, 18 e 19.

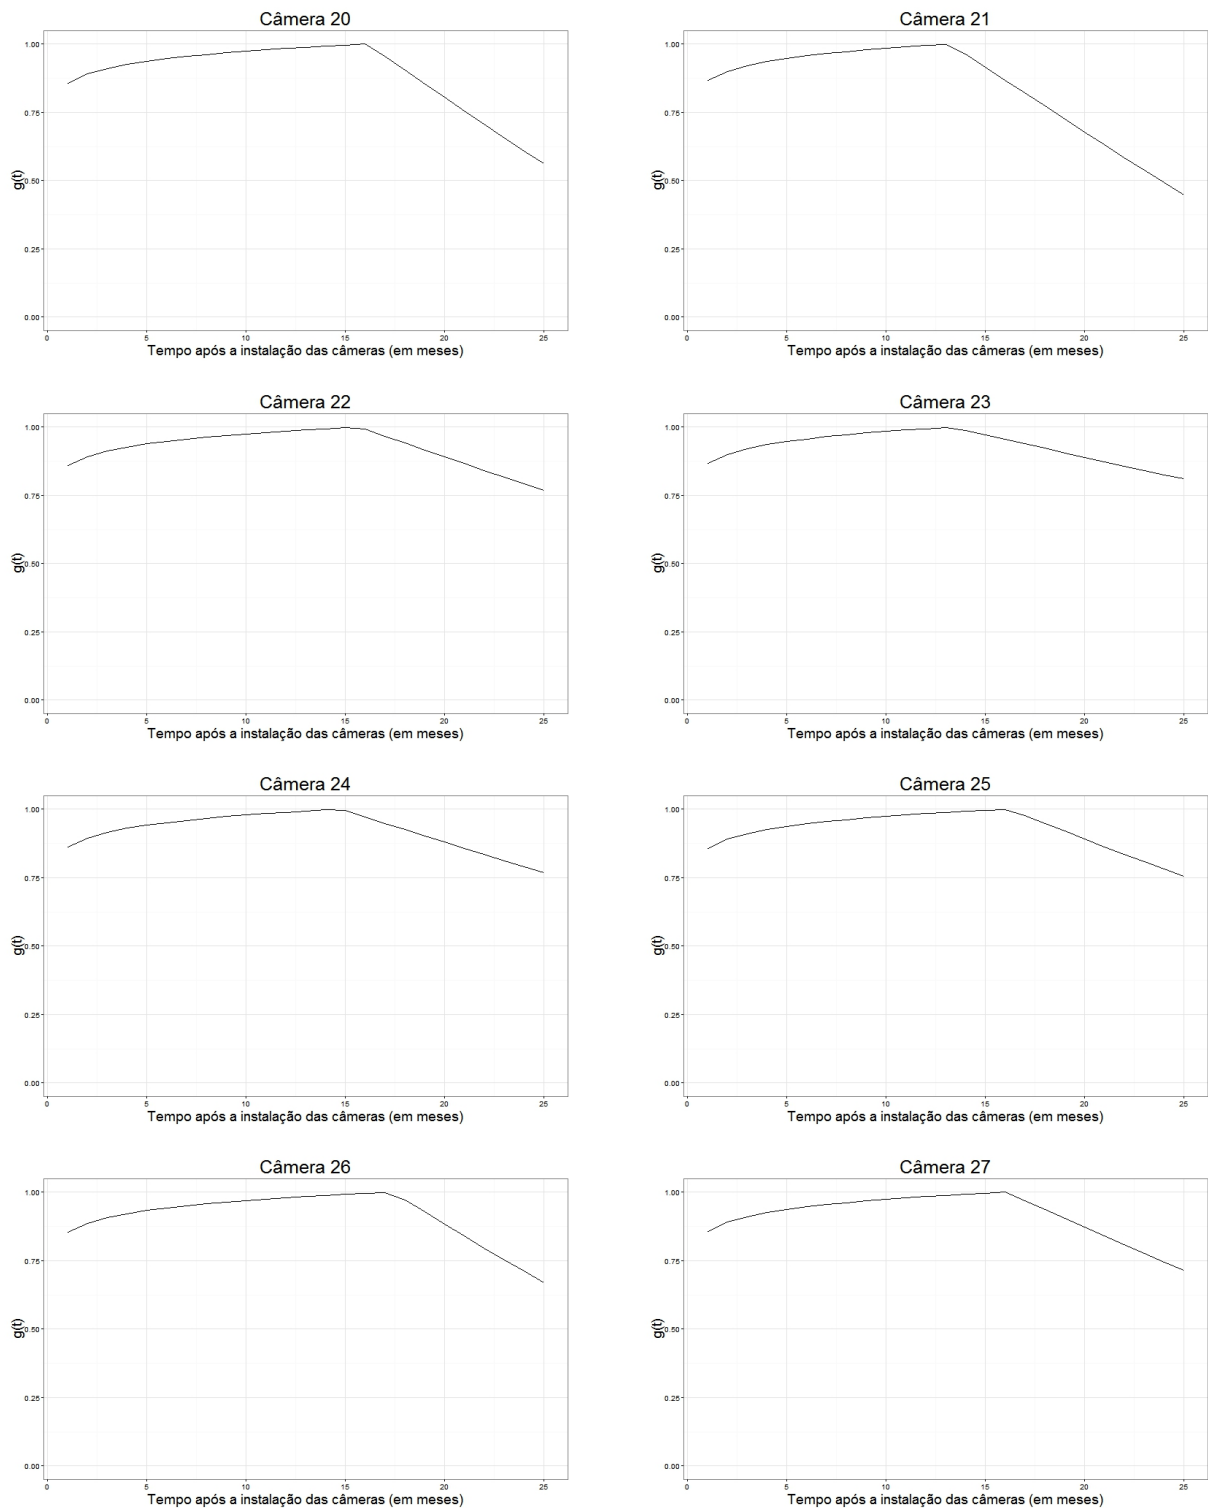


Figura E.3: Estimativa *a posteriori* da função  $g(t)$  para as câmeras 20, 21, 22, 23, 24, 25, 26 e 27.

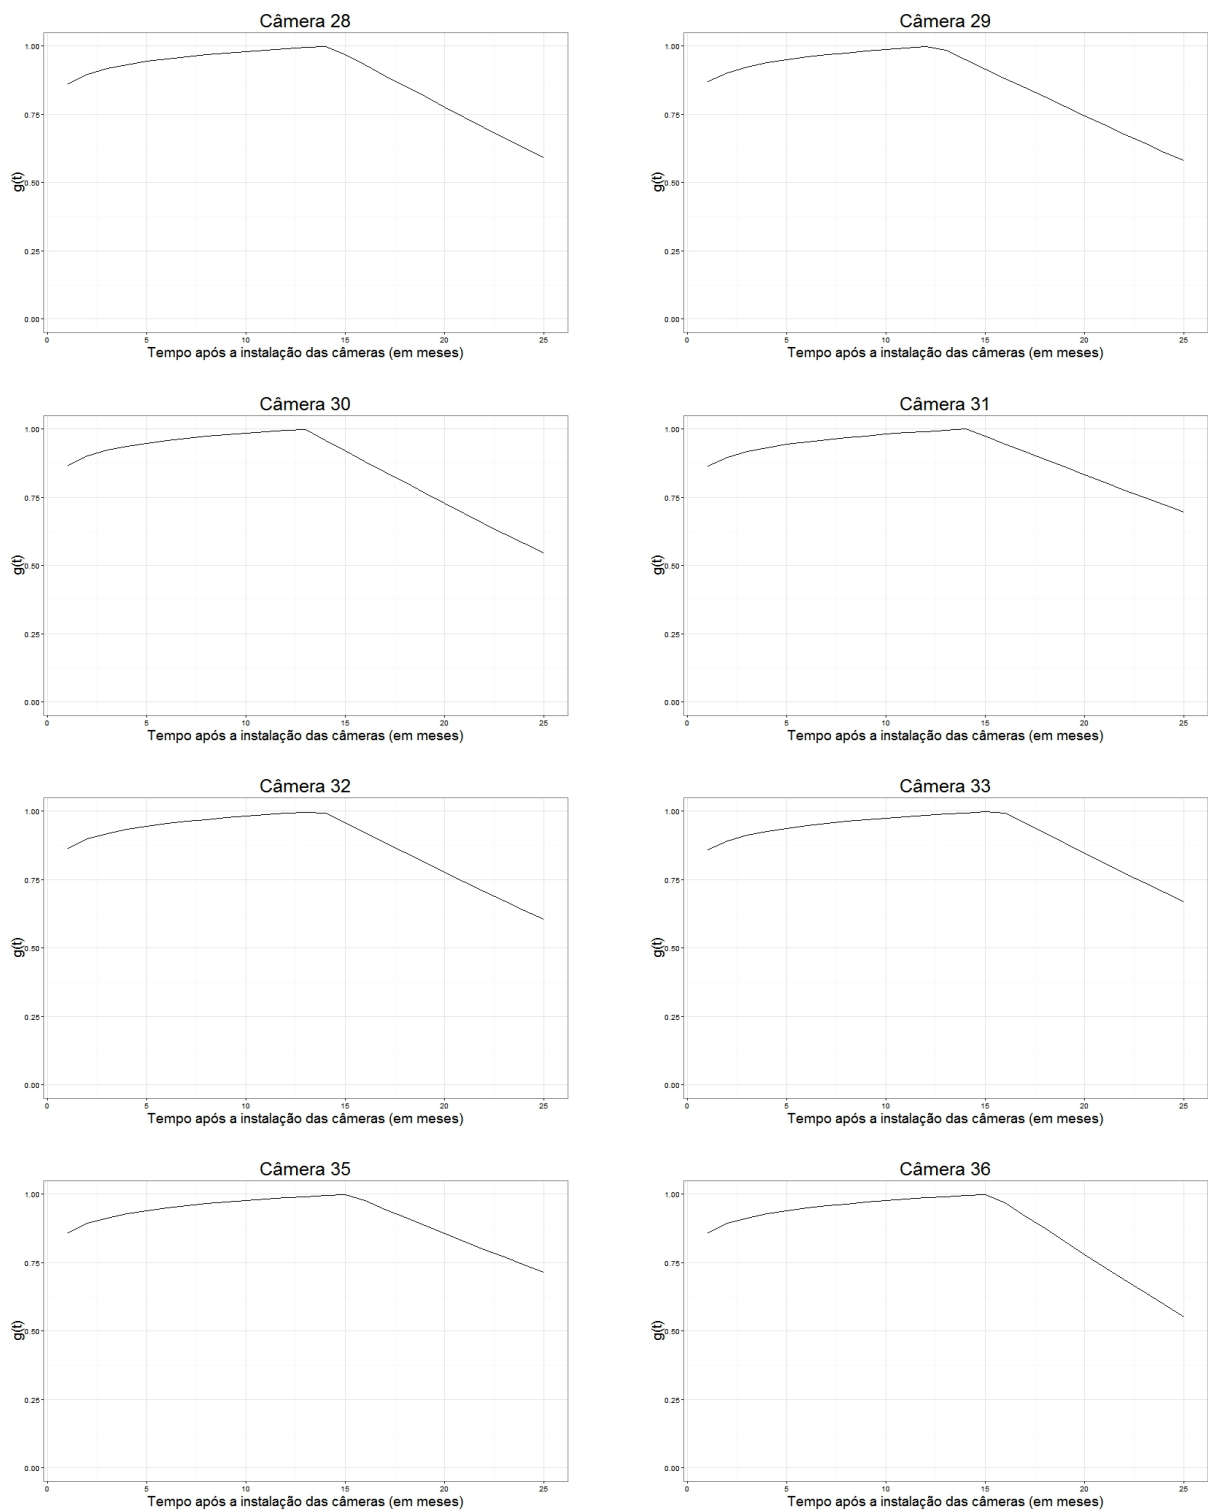


Figura E.4: Estimativa *a posteriori* da função  $g(t)$  para as câmeras 28, 29, 30, 31, 32, 33, 35 e 36.

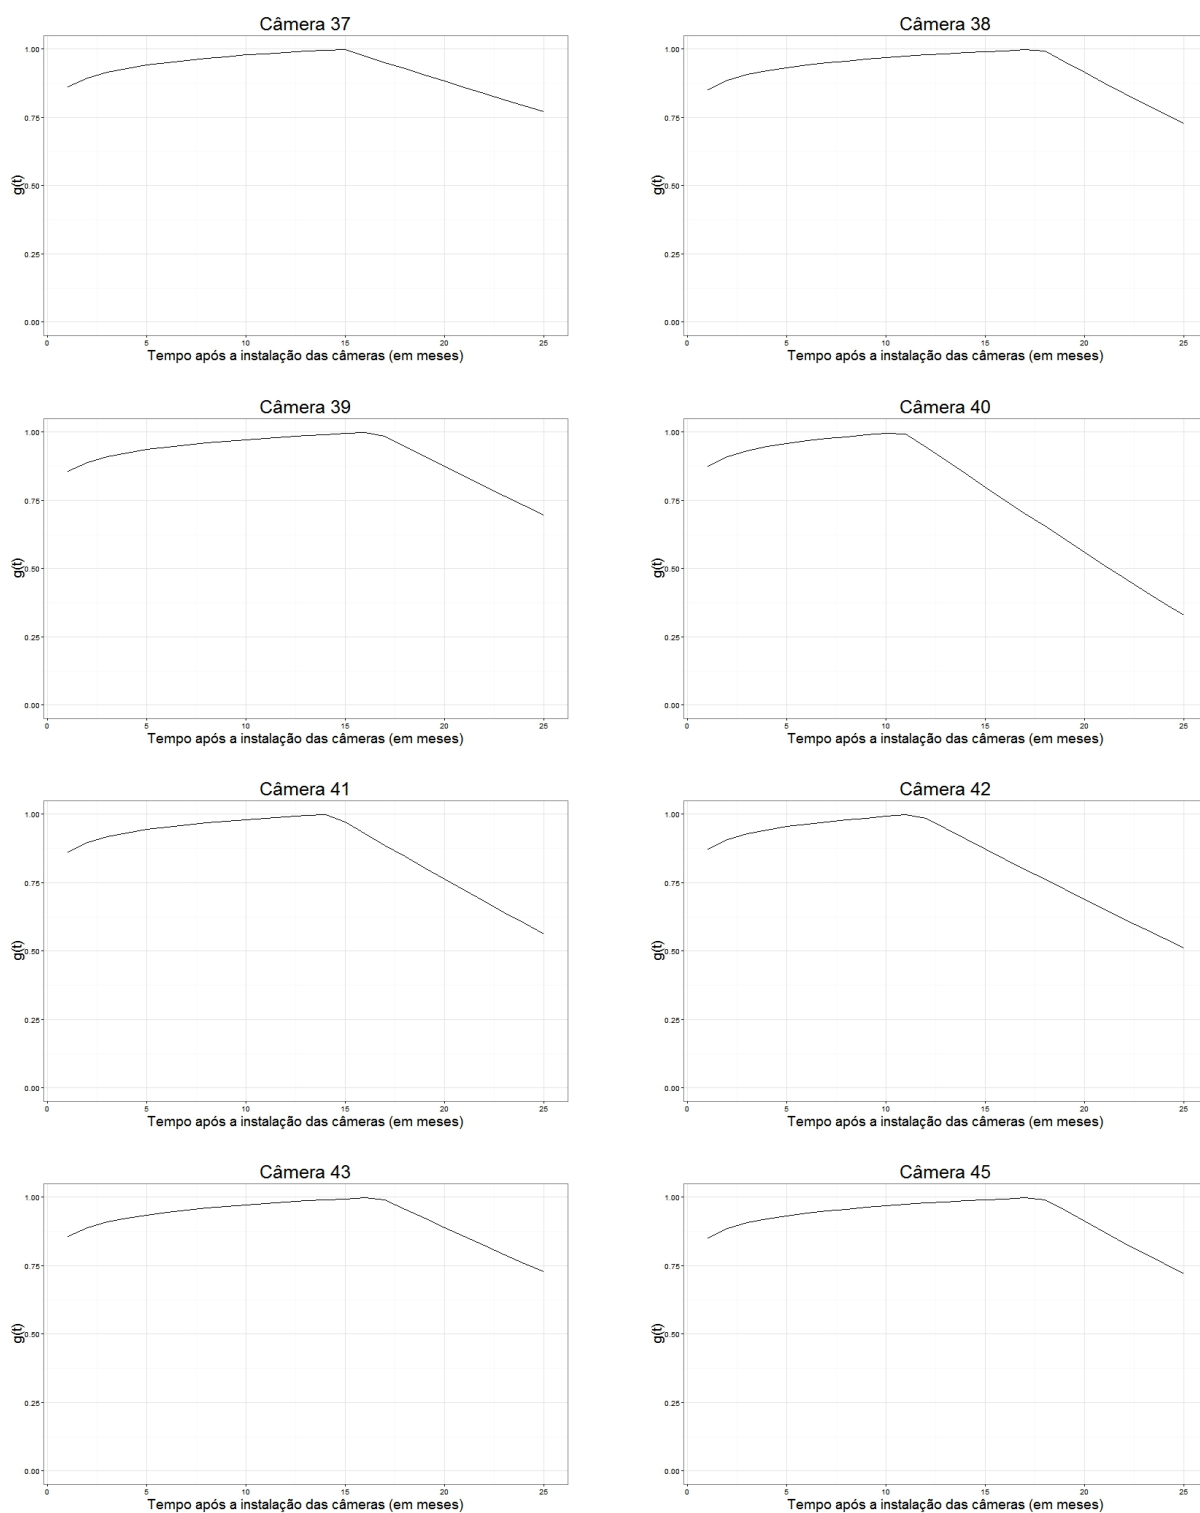


Figura E.5: Estimativa *a posteriori* da função  $g(t)$  para as câmeras 37, 38, 39, 40, 41, 42, 43 e 45.

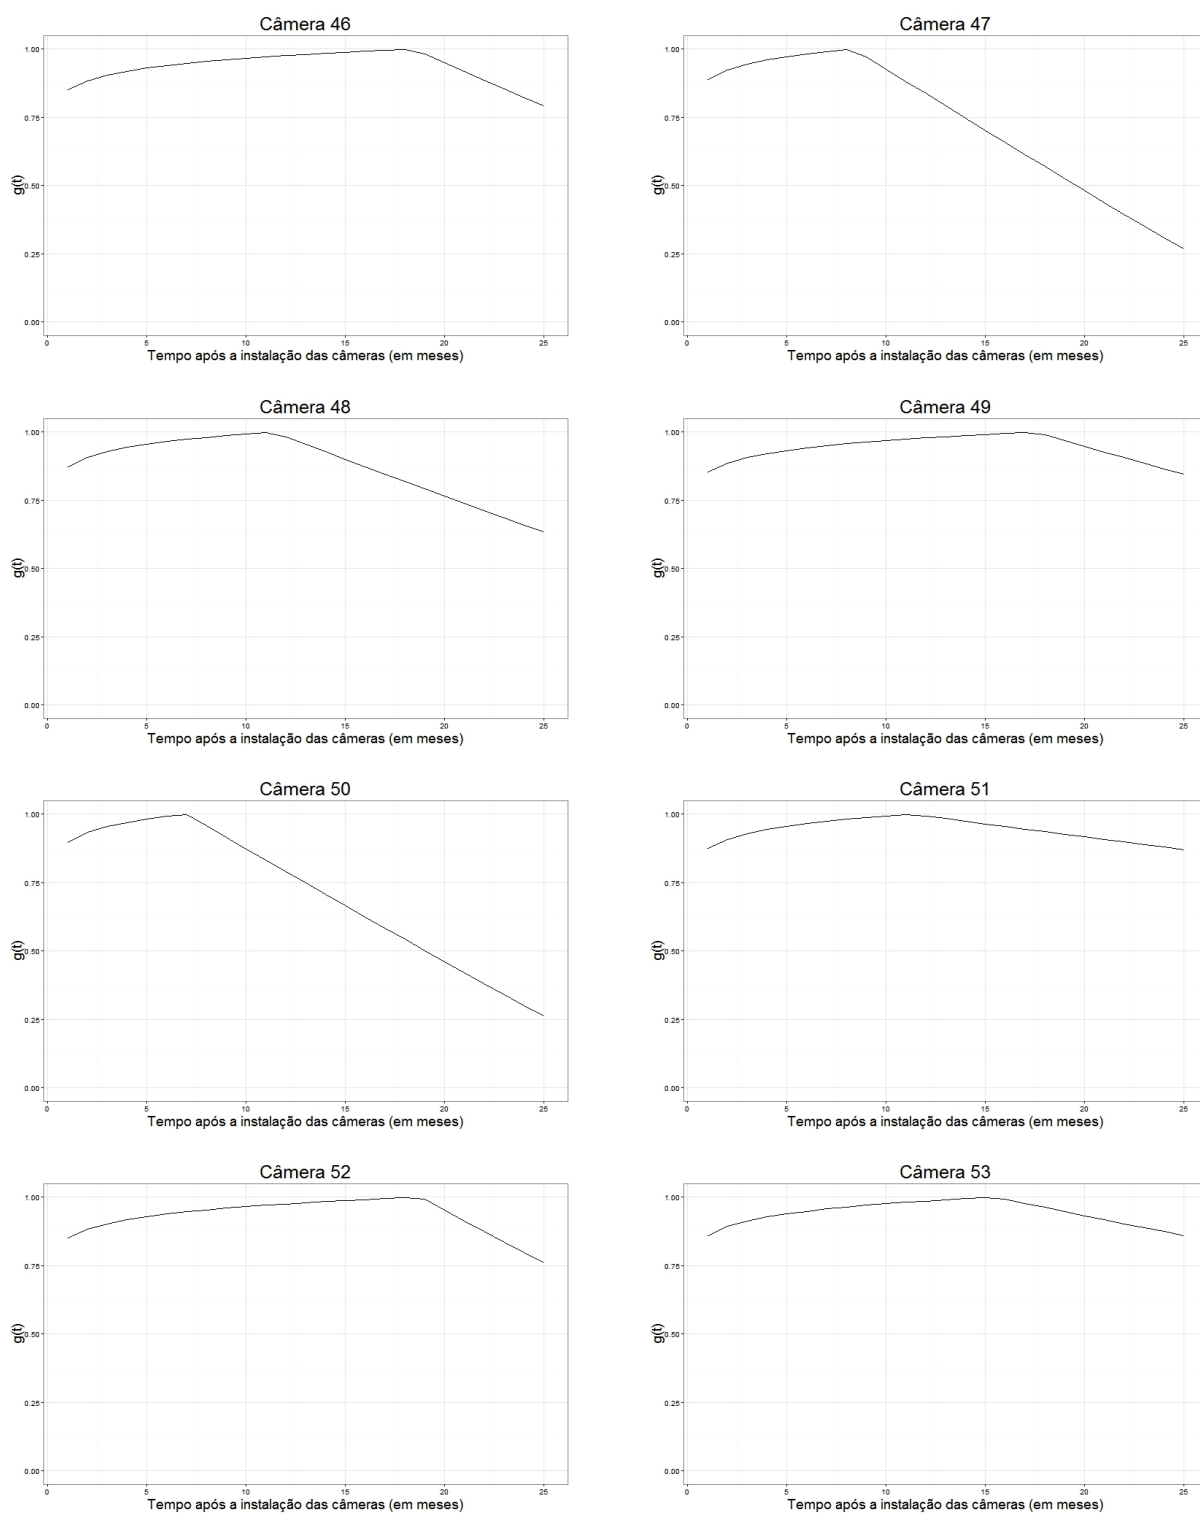


Figura E.6: Estimativa *a posteriori* da função  $g(t)$  para as câmeras 46, 47, 48, 49, 50, 51, 52 e 53.

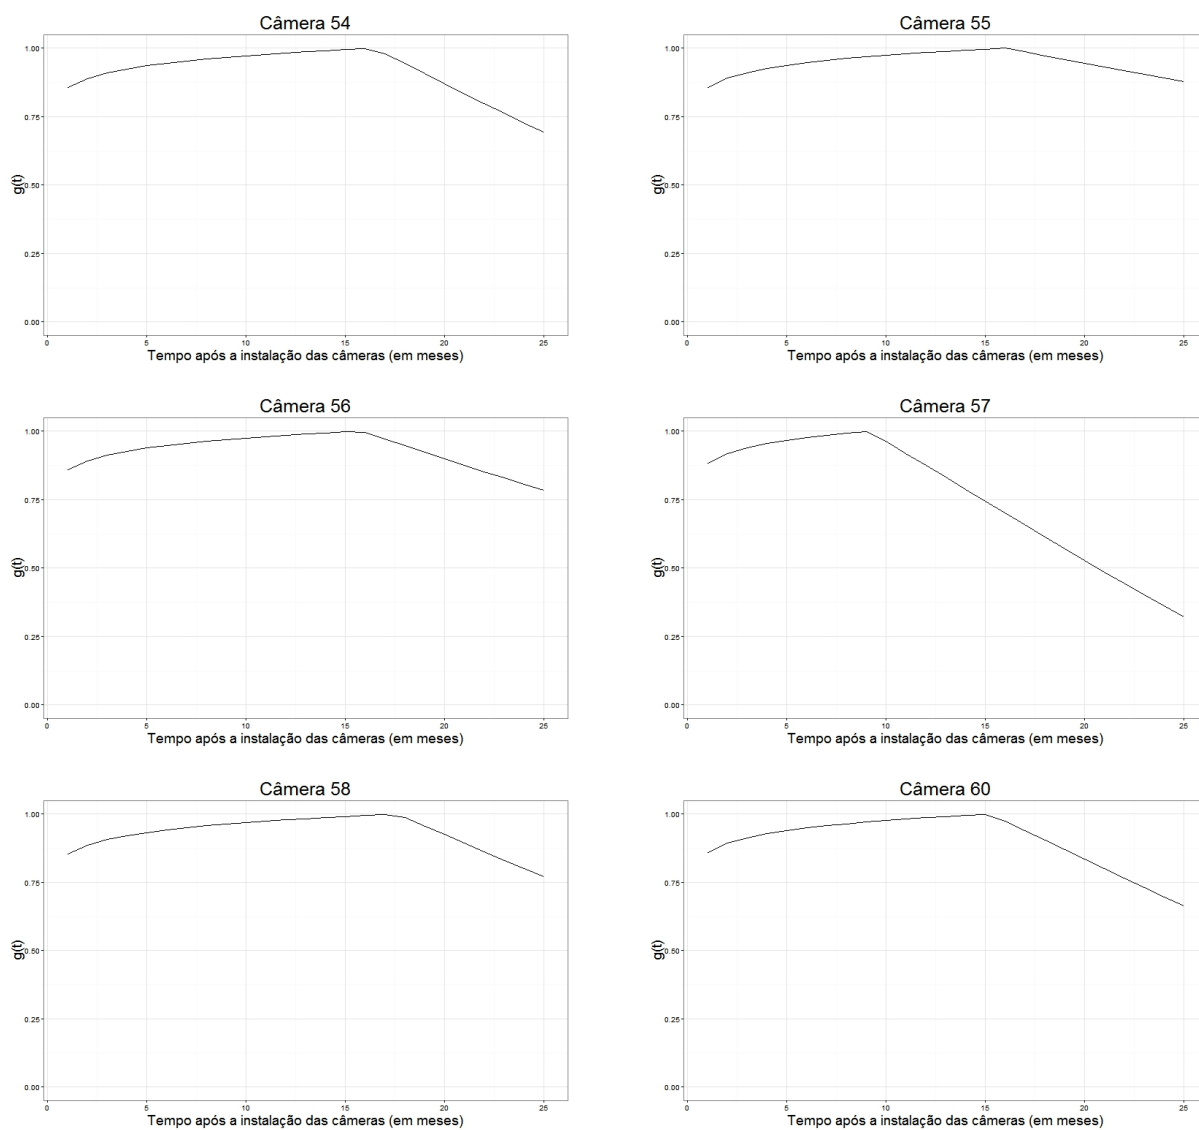


Figura E.7: Estimativa *a posteriori* da função  $g(t)$  para as câmeras 54, 55, 56, 57, 58 e 60.

## Referências Bibliográficas

- Armitage, R. (2002) To CCTV or not to CCTV? A review of current research into the effectiveness of CCTV systems in reducing crime.
- Bernardo, J. M. and Smith, A. F. M. (1994) *Bayesian Theory*. New York: John Wiley.
- Brown, B. (1997) Safer city centres: reviving the public realm. *Paul Chapman Publishing Ltd*, 132.
- (2010) Cctv in town centres:three case studies. *Crime Detection ans Prevention Series, London, Home Office*.
- Casella, G. and Robert, C. P. (2010) *Introducing Monte Carlo Methods with R*. Springer New York Dordrecht Heidelberg London.
- Christakos, G. (2000) *Modern spatiotemporal geostatistics*. Oxford University Press, USA.
- Diggle, P., Rowlingson, B. and Su, T. (2005) Point process methodology for on-line spatio-temporal disease surveillance. *Environmetrics*, 423–434.
- Diggle, P. J. and Rodrigues, A. (2010) A class of convolution-based models for spatio-temporal processes with non-separable covariance structure. *Scandinavian Journal of Statistics*, 553–567.
- Eddelbuettel, D. and Francois, R. (2011) *Rcpp: Seamless R and C++ Integration*. Journal of Statistical Software. URL<http://www.jstatsoft.org/v40/i08/>.
- Ehlers, R. S. and Justiniano, P. (2003) Introdução a Inferência Bayesiana. *Tech. rep.*, Universidade Federal do Paraná.
- Gamerman, D. and Lopes, H. F. (2006) *Markov Chain Monte Carlo: Stochastic Simulation for Bayesian Inference*. New York: Chapman and Hall, 2 edn.
- Gelfand, A. E. and Smith, A. F. M. (1990) Sampling-based approaches to calculating marginal densities. *Journal of the American Statistical Association*, **85**, 398–409.

- Geman, S. and Geman, D. (1984) Stochastic relaxation, gibbs distributions and the bayesian restoration of images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **6**, 721–741.
- Gill, M. and Spriggs, A. (2005) *Assessing the impact of CCTV*. Home Office Research, Development and Statistics Directorate.
- Harvill, J. L. (2010) Spatio-temporal processes. *Wiley Interdisciplinary Reviews: Computational Statistics*, 375–382.
- Hastings, W. K. (1970) Monte carlo sampling methods using markov chains and their applications. *Biometrika*, **57**, 97–109.
- Maia, A. (2005) *Um Novo Teste para a Hipótese de Separabilidade em Processos Pontuais*. Master's thesis, Universidade Federal de Minas Gerais.
- Mariani, C. G. A. (2011) A criminalidade no Rio Grande do Sul: Uma análise espacial para o período 2000-2008. XIV Encontro de Economia da Região Sul - ANPECSUL, Florianópolis, SC.
- McCahill, M. (2002) *The surveillance web: the rise of visual surveillance in an english city*. Willan Publishing.
- Menezes, F., Silva, J., Moreira, E., Meneses, J., Magalhães, D., Barbosa, A. and Oliveira, C. (2008) Distribuição espaço-temporal da raiva bovina em Minas Gerais, 1998 a 2006. *Arquivo Brasileiro de Medicina Veterinária e Zootecnia*, **60**, 566–573.
- Metropolis, N., Rosenbulth, A. W., Rosenbulth, M. N., Teller, A. H. and Teller, E. (1953) Equation of state calculations by fast computing machine. *Journal of Chemical Physics*, **21**, 1087–1091.
- Migon, H. S. and Gamerman, D. (1999) *Statistical Inference: an Integrated Approach*. London: Arnold.
- Moller, J. and Díaz-Avalos, C. (2010) Structured spatio-temporal shot-noise cox point process models, with a view to modelling forest fires. *Scandinavian Journal of Statistics*, 2–25.
- NIMBLE Development Team (2014) *NIMBLE Users Manual, Version 0.4*. URL <http://r-nimble.org>.

- Norris, C. and Armstrong, G. (1999) *The maximum surveillance society: The rise of CCTV*. Berg Oxford.
- R Core Team (2014) *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria. URL <http://www.R-project.org/>.
- Rodrigues, A., Diggle, P. and Assuncao, R. (2010) Semiparametric approach to point source modelling in epidemiology and criminology. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 533–542.
- Rodrigues, A. and Diggle, P. J. (2012) Bayesian estimation and prediction for inhomogeneous spatiotemporal log-gaussian cox processes using low-rank models, with application to criminal surveillance. *Journal of the American Statistical Association*, 93–101.
- Silva, W. C. P. (2015) Análise Espaço-Temporal dos Roubos de Veículos Ocorridos Durante o Ano de 2013 nas Regiões das áreas de Segurança Pública Integrada 4 e 6 no Rio de Janeiro. *Revista Brasileira de Ciências Policiais*, **6**, 87–115.
- Simões, T. C. (2006) *Sistema de vigilância para detecção de interação espaço-tempo de eventos pontuais via superfícies acumuladas*. Master's thesis, Universidade Federal de Minas Gerais.
- Sturtz, S., Ligges, U. and Gelman, A. (2005) R2winbugs: A package for running winbugs from r. *Journal of Statistical Software*, **12**.
- Taquette, S. R., Matos, H. J., Rodrigues, A. O., Bortolotti, L. R. and Amorim, E. (2011) A epidemia de AIDS em adolescentes de 13 a 19 anos, no município do Rio de Janeiro: descrição espaço-temporal. *Revista da Sociedade Brasileira de Medicina Tropical*, **44**, 467–470.