



UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
ESCOLA DE ADMINISTRAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO



MOACIR ALMEIDA SIMÕES JÚNIOR

**Adoção da estratégia de patrulhamento multiagente para otimização do policiamento preventivo na cidade de Porto Alegre, RS**

Porto Alegre  
2023

MOACIR ALMEIDA SIMÕES JÚNIOR

**Adoção da estratégia de patrulhamento multiagente para a otimização do policiamento preventivo na cidade de Porto Alegre, RS**

Dissertação apresentada como requisito à obtenção do grau de Mestre em Administração pela Universidade Federal do Rio Grande do Sul – UFRGS, Escola de Administração.

Orientador: Prof. Dr. Denis Borenstein

Porto Alegre  
2023

#### CIP - Catalogação na Publicação

Simões Júnior, Moacir Almeida  
Adoção da estratégia de patrulhamento multiagente  
para otimização do policiamento preventivo na cidade  
de Porto Alegre, RS / Moacir Almeida Simões Júnior. --  
2023.  
93 f.  
Orientador: Denis Borenstein.

Dissertação (Mestrado) -- Universidade Federal do  
Rio Grande do Sul, Escola de Administração, Programa  
de Pós-Graduação em Administração, Porto Alegre,  
BR-RS, 2023.

1. Administração. 2. Pesquisa Operacional. 3.  
Polícia. 4. Análise Criminal. 5. Análise Preditiva. I.  
Borenstein, Denis, orient. II. Título.

## **FOLHA DE APROVAÇÃO**

MOACIR ALMEIDA SIMÕES JÚNIOR

### **Adoção da estratégia de patrulhamento multiagente para a otimização do policiamento preventivo na cidade de Porto Alegre, RS**

Dissertação apresentada como requisito à obtenção do título de mestre em Administração da Escola de Administração da Universidade Federal do Rio Grande do Sul.  
Orientador: Prof. Dr. Denis Borenstein

**Aprovado em:** Porto Alegre, 17 de Abril de 2023.

BANCA EXAMINADORA:

---

Prof. Dr. Dante Augusto Couto Barone  
Universidade Federal do Rio Grande do Sul

---

Prof. Dr. Luciano Ferreira  
Universidade Federal do Rio Grande do Sul

---

Prof. Dr. Pablo Cristini Guedes  
Universidade Federal do Rio Grande do Sul

## **AGRADECIMENTOS**

A minha noiva, Bruna, que me incentivou e compreendeu os momentos de ausência por conta da realização deste trabalho.

Aos meus pais, Moacir e Eloiza, por terem me ensinado que as conquistas na vida vêm com esforço e fé.

Ao meu orientador, Denis Borenstein, professores e colegas do Programa de Pós-Graduação em Administração, em especial ao colega de farda, Costa Limeira, pelos ensinamentos e troca de ideias que possibilitaram avanços na construção deste trabalho.

## RESUMO

A presente dissertação tem por objeto o estudo do problema de otimização de roteamento de patrulhas policiais para minimização da ociosidade em *hotspots* e do tempo de resposta no atendimento de ocorrências, por meio da predição de locais de recorrência de crimes, usando estratégia multiagente de policiamento. As patrulhas operam em jornadas de serviço determinadas, em meio a pé, de bicicleta, motorizado e a cavalo, e movimentos controlados por central de operações, a fim de realizar ações preventivas de patrulhamento e permanência, em pontos de maior densidade de ocorrências, e atendimento de ocorrências. Para a definição dos *hotspots* são adotadas técnicas de análise preditiva sobre dados históricos de ocorrências por horário, dia da semana e mês do ano, identificando sazonalidades, e estruturas notáveis (bares, escolas, parques etc.), cuja presença no espaço pode interferir na ocorrência de crimes. Quanto ao local de aplicação, a pesquisa tratará da área de 9º Batalhão de Polícia Militar da Brigada Militar, responsável pelo policiamento preventivo no Centro Histórico e bairros adjacentes de Porto Alegre, RS. Serão utilizadas informações dos registros de ocorrências dos anos de 2015, 2016, 2017, 2018, 2019, 2020 e 2021 da Secretaria da Segurança Pública e dados abertos quanto às estruturas notáveis presentes na região. O modelo formulado será implementado, por meio de simulação, utilizando-se dados do emprego operacional da Brigada Militar, no espaço determinado, a fim de aferir a eficácia do modelo na prevenção da criminalidade, a otimização dos recursos disponíveis e o aumento da sensação de segurança das comunidades atingidas.

**Palavras-chave:** Simulação; Problema de Roteamento de Patrulhas Policiais; Problema de Patrulhamento Multiagente; Análise Criminal; Análise Preditiva; Policiamento Preventivo.

## ABSTRACT

The purpose of this dissertation is to study the problem of optimizing the routing of police patrols to minimize idleness in hotspots and response time in attending to police incidents, by predicting crime recurrence locations, using a multi-agent policing strategy. Patrols operate on specific duty days, on foot, by bike, motorized and on horseback, and movements controlled by an operations center, in order to carry out preventive patrolling and permanence actions, in points with a higher density of occurrences, and to respond to incidents. For the definition of hotspots, predictive analysis techniques are adopted on historical data of occurrences by time, day of the week and month of the year, identifying seasonality, and notable structures (bars, schools, parks, etc.), whose presence in space can interfere with the occurrence of crimes. As for the place of application, the research will deal with the area of the 9th Military Police Battalion of the *Brigada Militar*, responsible for preventive policing in the Historic Center and adjacent neighborhoods of Porto Alegre, RS. Information from the records of occurrences from the years 2015, 2016, 2017, 2018, 2019, 2020 and 2021 of the Secretariat of Public Security and open data regarding the notable structures present in the region will be used. The formulated model will be implemented, through simulation, using data from the operational use of the *Brigada Militar*, in the given space, in order to assess the effectiveness of the model in preventing crime, optimizing available resources and increasing the sense of belonging. safety of affected communities.

**Keywords:** Simulation, Operational Research; Police Patrol Routing Problem; Multi-Agent Patrol Problem; Criminal Analysis; Predictive Analytics; Preventive Policing

## Lista de Figuras

Figura 1 - O processo de negócio de policiamento conduzido por previsão de dados .....	35
Figura 2 - Cartão Programa.....	45
Figura 3 - Processo de resolução de um problema.....	48
Figura 4 - Fluxograma da preparação dos dados.....	62
Figura 5 - Algoritmo de busca da solução .....	64
Figura 6 - Área do 9ºBPM .....	68
Figura 7 - Área do 9ºBPM - Grids Hexagonais (350 metros de lado).....	70
Figura 8 - Ocorrências e estruturas notáveis na circunscrição dos Grids Hexagonais .....	71
Figura 9 - Área do 9ºBPM - Grids de interesse .....	72
Figura 10 - 50 hotspots e os respectivos locais de parada das patrulhas policiais. ..	72
Figura 11 - (a) Eventos criminais de 2015 a 2021; (b) Câmeras de Vigilância; (c) Paradas de ônibus; (d) Escolas, Colégios e Universidades; (e) Estabelecimentos comerciais; (f) Bares e Restaurantes. ....	73
Figura 12 - Rota da patrulha.....	79



## Lista de Quadros

Quadro 1 - Notações .....	54
Quadro 2 - Processos de Policiamento .....	63
Quadro 3 - Funcionamento do sistema .....	65
Quadro 4 - Argumentos de pesquisa nos sistemas.....	69
Quadro 5 - Lista de estruturas notáveis .....	69
Quadro 6 - Descrição da rota de patrulha .....	79

## Lista de Tabelas

Tabela 1 - Dados demográficos de região de Porto Alegre.....	67
Tabela 2 - Importância das variáveis para a predição.....	74
Tabela 3 - Escolha Aleatória .....	76
Tabela 4 - Ociosidade Média.....	77
Tabela 5 - Tempo-Resposta Médio .....	77
Tabela 6 – Índice de Precisão da Previsão .....	78
Tabela 7 - Comparação do Tempo-Resposta .....	80

## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>12</b>
1.1 PROBLEMA .....	15
1.2 OBJETIVOS .....	16
1.2.1 Objeto geral:.....	16
1.2.2 Objetivos específicos:.....	16
<b>2 REFERENCIAL TEÓRICO.....</b>	<b>17</b>
2.1 PROBLEMA DE ROTEAMENTO DE PATRULHAS POLICIAIS.....	17
2.2 PROBLEMA DE PATRULHAMENTO MULTIAGENTE .....	22
2.3 DEFINIÇÃO DE HOTSPOTS .....	28
2.4 ANÁLISE PREDITIVA.....	34
2.5 ESTRATÉGIAS DE DECISÃO NO PATRULHAMENTO .....	39
<b>3 CONTEXTUALIZAÇÃO .....</b>	<b>42</b>
<b>4 METODOLOGIA.....</b>	<b>48</b>
4.1 IDENTIFICAÇÃO DO PROBLEMA .....	49
4.2 FORMULAÇÃO DO MODELO .....	51
4.3 VALIDAÇÃO DA SOLUÇÃO .....	51
<b>5. DESENVOLVIMENTO DO MODELO.....</b>	<b>54</b>
5.1 MODELO PROPOSTO .....	54
5.2 SELEÇÃO DE HOTSPOTS.....	61
<b>6. APLICAÇÃO DO MODELO .....</b>	<b>67</b>
6.1 CRIAÇÃO DOS HOTSPOTS.....	67
6.2 ANÁLISE PREDITIVA DA CRIMINALIDADE .....	73
6.3 DEFINIÇÃO DO CENÁRIO DE AVALIAÇÃO .....	74
6.4 ANÁLISE DOS RESULTADOS .....	75
6.5 DISCUSSÃO .....	78
<b>7 CONCLUSÃO .....</b>	<b>83</b>
<b>REFERÊNCIAS.....</b>	<b>86</b>
<b>ANEXO ÚNICO .....</b>	<b>92</b>

## 1 INTRODUÇÃO

O patrulhamento policial trata-se de uma forma efetiva de prevenção a ocorrência de crimes (CHEN; CHENG; WISE, 2017; LI et al., 2011; REIS et al., 2006; RUAN et al., 2005; RUMI; QIN; SALIM, 2020). A presença policial tem a propriedade de lembrar os cidadãos de suas obrigações perante a lei, assim como, conformar os delinquentes na sua decisão de cometer crimes, evitando que estes aconteçam (DEWINTER et al., 2020; GODWIN; STASKO, 2017). Como um indicador óbvio e visível de ameaça de sanção, o patrulhamento policial ocupa lugar central nas estratégias de controle do crime. A presença da patrulha é uma ameaça visível que aumenta as certezas objetivas e subjetivas de punição pública (KOPER, 1995).

Em uma ronda policial, uma unidade de patrulha (geralmente um ou dois policiais) é despachada para conduzir a vigilância por meio de patrulhamento. As patrulhas percorrem diferentes locais da área, particularmente os pontos críticos do crime, a fim de deter os crimes pela sua presença e para intervir se um crime estiver em andamento. Cada unidade policial (Batalhão de Polícia Militar, no caso brasileiro) possui um conjunto de várias rondas de patrulha (CHEN; CHENG; WISE, 2017).

Tradicionalmente, a patrulha realiza rotas aleatórias na tentativa de mitigar os riscos de crimes, considerando a experiência dos policiais. No entanto, o roteamento aleatório diminui as chances de garantir a presença de um policial durante um evento de crime (CHEN; CHENG; WISE, 2017; RUMI; QIN; SALIM, 2020). Concentrar recursos limitados em locais com aglomerados de crimes parece ser uma escolha mais racional e eficiente (LI et al., 2011; TAYEBI et al., 2014). O crime tende a se concentrar em locais específicos por razões que podem ser explicadas em relação à interação vítima e ofensor e às oportunidades que existem para cometer crimes (BRANTINGHAM; BRANTINGHAM, 1995; CHAINEY; TOMPSON; UHLIG, 2008; ECK; WEISBURD, 2015). Sendo assim, a rotina policial deve se adequar ao espaço e ao tempo, nos quais recorrentemente o crime se manifesta. A partir da análise dos históricos de ocorrências, pode-se realizar o mapeamento da densidade dos crimes, conforme sua localização. Os locais de maior de recorrência de crimes são chamados de *hotspots*. O risco para ocorrência de novos eventos criminosos pode ser medido

utilizando-se este conceito (DEWINTER et al., 2020; GODWIN; STASKO, 2017; LEIGH; DUNNETT; JACKSON, 2019).

Desta forma, busca-se o estabelecimento de policiamento preventivo focado na predição de crimes (DASH; SAFRO; SRINIVASAMURTHY, 2018), direcionado para os locais com maior chance de novos eventos criminais acontecerem, visando a cobertura regular e repetitiva (CHEN; CHENG; WISE, 2017). Infelizmente, em uma situação reativa, a presença policial se dá quando já ocorreram eventos criminais, que afetam negativamente a população em análise. Julga-se importante a adição de um conjunto de ferramentas de análise preditiva como forma de aprimorar os sistemas de análise atuais, passando de um paradigma exclusivamente reativo para um paradigma proativo (MACIEJEWSKI et al., 2011).

Para o patrulhamento policial são empregados policiais a pé, a cavalo, de bicicleta, com veículos motorizados (carros e motocicletas) e, até mesmo drones, operados à distância. O foco deste trabalho é o policiamento, nas formas a pé, a bicicleta e motorizado, para cobertura dos espaços com maior prioridade para se evitar a ocorrência de crimes. Cada patrulha trata-se de um agente no ambiente a ser patrulhado. A mudança na posição do agente na busca da ocupação dos *hotspots*, considerando os dados criminais, deve ser orquestrada de forma a otimizar a distribuição no espaço das patrulhas, evitando-se sobreposições e reforçando a presença nos locais de maior criticidade para o crime. Salienta-se que os recursos, em regra, são mais limitados do que as demandas operacionais (RUMI; SHAO; SALIM, 2020).

Neste sentido, cabe destacar os avanços tecnológicos que permitem o roteamento de patrulhas em tempo real. Com a introdução do Sistema de Posicionamento Global (*Global Position System - GPS*), em 1996, o desenvolvimento e uso generalizado de telefones celulares inteligentes, aliados a Sistemas de Informações Geográficas (*Geographic Informations Systems - GIS*) precisos, pode-se rastrear e gerenciar a frota em tempo real e seus custos efetivamente. Embora, tradicionalmente, seja um processo de duas etapas (ou seja, planejar e executar), o roteamento de veículos agora pode ser feito dinamicamente, apresentando maiores oportunidades para reduzir custos operacionais, melhorar o atendimento ao usuário e reduzir o impacto ambiental (PILLAC et al., 2013).

Para tanto, devem ser estabelecidas dinamicamente rotas de patrulha eficientes para garantir que a unidade de patrulha cubra os locais críticos nos

momentos de maior necessidade. O primeiro passo é identificar, a partir dos dados históricos de crimes, os locais estratégicos de patrulha na área, por exemplo, pontos de maior incidência da criminalidade e de infraestruturas notáveis (escolas, postos de saúde, comércio, bares etc.). Depois que a previsão da tendência do crime é feita, a distribuição esperada do crime nas dimensões espacial e temporal é especificada. Modelos de predição podem ser introduzidos para indicar os locais de interesse. Com base nisso, é gerada uma rota de patrulha que maximiza a eficácia da patrulha em um horizonte de planejamento desejado (por exemplo, um turno de patrulha de 8 horas). Quando informações importantes são recebidas e a previsão precisa ser atualizada, o procedimento é repetido para gerar uma rota de patrulha atualizada (CHEN; CHENG; WISE, 2017).

Neste sentido, o problema que se busca resolver é de otimização do emprego das patrulhas policiais de um dado local, considerando a probabilidade de eventos criminais com base no histórico de ocorrências policiais e estruturas notáveis, com vistas à minimização do tempo de ociosidade da presença policial nos chamados *hotspots* e do tempo de resposta médio no atendimento de ocorrências, com inspiração em estratégias multiagente. Estas são usadas para orientar as patrulhas a se direcionarem para lugares que foram visitados menos recentemente, considerando outros fatores, como distância e coordenação (CHEN; CHENG; WISE, 2017). Apresentam bom desempenho no emprego de robôs na visita regular de lugares importantes de um ambiente, sem necessariamente ir a todos (PORTUGAL; ROCHA, 2013). No entanto, a maioria das estratégias pioneiras são desenvolvidas no contexto da patrulha robótica e negligenciam os aspectos de imprevisibilidade nas rotas de patrulha e de robustez às influências da resposta de emergência (CHEN; CHENG; WISE, 2017).

E considerado como restrições no problema, o quantitativo de patrulhas policiais disponíveis, sejam a pé, motorizadas e de bicicleta. Cada tipo de patrulha pode trabalhar em regimes de jornada de serviço diferentes (6, 8 ou 12 horas) e com início de operação em horários diversos, conforme a necessidade. A velocidade média, em cada tipo de patrulha, interfere no tempo gasto de deslocamento entre os *hotspots*, sendo uma restrição importante. Além disso, destaca-se que no patrulhamento a pé e de bicicleta, restrições viárias, como sentido da via e locais para realização do retorno não são considerados, diferentemente, de quando se utiliza viaturas, muito embora, em situações emergenciais, tenham livre trânsito.

Ressalta-se que os agentes criminosos inteligentes podem observar e explorar padrões nas rotas. Neste sentido, os próximos pontos de visita serão gerados dinamicamente. Para tanto a alocação de um novo ponto de parada para as patrulhas com certo grau de aleatoriedade (CHEN; CHENG; WISE, 2015; TSAI et al., 2010) torna-se crucial. Até porque, algoritmos determinísticos possibilitam a geração de rotas repetidas, as quais podem ser compreendidas pelos agentes criminosos, passando agir nos locais de certeza da ausência policial (LI et al., 2011). Vale destacar também que nos deslocamentos entre os *hotspots* as patrulhas o uso dos caminhos mais curtos (menor custo de tempo) precisa ser considerado, a fim de garantir a cobertura de um maior número de *hotspots*. Além disso, é importante que o ganho na execução da visita em novo local de patrulhamento considere o peso de cada *hotspot* na criminalidade, ou seja, os locais com maior densidade criminal devem ser mais visitados pelas patrulhas.

Este documento apresenta um projeto para o desenvolvimento de um modelo matemático para o planejamento otimizado de rotas policiais dinamicamente, considerando a área dos batalhões de polícia militar do Município de Porto Alegre. Destaca-se que desde 2015 as ocorrências policiais na cidade são georreferenciadas, possibilitando a identificação com precisão dos locais de incidência de crimes. Ademais, a partir do final de 2021, as patrulhas policiais passaram a ser localizáveis, por meio de dispositivo de GPS (Global Position System) presente no sistema de radiocomunicação e instalado nas viaturas policiais.

## 1.1 PROBLEMA

Em face do acima exposto, apresenta-se o seguinte problema de pesquisa:

*É possível estabelecer um sistema de otimização dinâmico de roteamento de patrulhas policiais para minimização da ociosidade nos hotspots e o tempo médio de resposta, inspirado em estratégia multiagente, sabendo-se que as patrulhas operam em jornadas de serviço determinadas e movimentos controlados por central de operações, a fim de realizar o atendimento de ocorrências e ações preventivas de patrulhamento e permanência, em pontos de maior densidade de ocorrências e*

*estruturas notáveis, considerando-se a análise preditiva sobre dados históricos por horário, dia da semana e mês do ano?*

## 1.2 OBJETIVOS

### 1.2.1 Objeto geral:

Formular o problema de roteamento dinâmico de patrulhas policiais, inspirado em estratégia multiagente de policiamento.

### 1.2.2 Objetivos específicos:

- Aplicar análise preditiva sobre dados históricos de ocorrências policiais para identificar *hotspots*.
- Desenvolver um modelo preditivo de crimes, com uso de *hotspots*, relacionados aos locais com maior risco de reincidência de ocorrências;
- Usar método inspirado na estratégia multiagente de policiamento para a identificação de rotas de cobertura de *hotspots*, e a minimização da ociosidade em tais pontos e o tempo médio de resposta no atendimento de ocorrências;
- Validar o modelo desenvolvido.



## 2 REFERENCIAL TEÓRICO

### 2.1 PROBLEMA DE ROTEAMENTO DE PATRULHAS POLICIAIS

O problema de roteamento de patrulhas de policiamento possui peculiaridades que o diferencia dos problemas clássicos de roteamento de veículos (DEWINTER et al., 2020). O objetivo central da polícia é prevenir e reduzir crimes, assim como, responder a emergências e desastres. A presença ou ausência do policial no tempo e espaço influencia a tomada de decisão para o cometimento de crimes pelos delinquentes. Neste sentido, a ação proativa da polícia se dá na prevenção. A fim dar efetividade na redução de crimes, o policiamento proativo tem seu foco em áreas específicas, chamadas de *hotspots*. Dada a escassez de recursos policiais, uma eficiente estratégia de alocação de recursos para dissuasão do crime deve ser estabelecida.

A presença visível da polícia aumenta a certeza de detecção e apreensão, aumentando a percepção de risco dos potenciais infratores nessa área. Esta abordagem orientada para a localização parece ser o meio mais eficaz e prático para aumentar os efeitos dissuasores da patrulha preventiva. Ao mesmo tempo, não está totalmente claro até que ponto essa abordagem e outras abordagens de saturação deslocam o crime ou por quanto tempo seus efeitos podem ser mantidos (KOPER, 1995).

Zhang e Brown (2013) identificam três grandes tipos de estratégias de patrulha para policiais: patrulha ativa, patrulha aleatória e patrulha dirigida. Em patrulha ativa, os policiais devem usar todas as oportunidades para descobrir, detectar, observar e interditar o evento incomum. Patrulha aleatória significa que as rotas de patrulha devem ser aleatórias e variadas para que os comportamentos de patrulha não sejam previstos por potenciais criminosos. Em patrulha dirigida, os policiais envidam mais esforços para locais de crime para que possam responder rapidamente e reduzir os crimes em pontos quentes. Tais estratégias podem ser utilizadas de forma conjugada, conforme os fins que se busca alcançar.

No contexto do clássico do problema de roteamento de veículos, Dewinter *et al* (2020) caracterizam o problema de roteamento de patrulhas policiais, como aquele em que os policiais iniciam o trabalho a partir de um depósito (sede do batalhão de polícia militar, no caso). As patrulhas deixam o depósito e dirigem-se para os locais de atuação. Quando em patrulhamento a unidade pode ser despachada para uma chamada de emergência. Tais eventos não são conhecidos *a priori*. As chamadas chegam em tempo real para um centro de despacho, o qual dirige um veículo para o local. O veículo deixa de responder sua tarefa de prevenção, por exemplo, para responder a uma chamada. Conforme a urgência da chamada (código de prioridade), o tempo de resposta deve ser minimizado. Terminado o atendimento, a patrulha retorna a sua atividade de rotina. E após realizar suas atividades, retorna ao depósito.

A minimização do tempo de resposta das patrulhas aos chamados passa também pela otimização dos locais de depósito das unidades. Além disso, a capacidade de policiais disponíveis deve relevar os padrões de concentração dos crimes no espaço e no tempo, o qual difere-se no horário do dia, no dia da semana e no mês (Ver Seção 2.3). A dosagem de policiamento precisa ser estabelecida, ou seja, a frequência e duração das patrulhas, baseada na quantificação do efeito visível da presença policial no tempo e no espaço, com vistas a deter o crime (Ver Seção 2.5). Para confundir os criminosos e deter o crime, as rotas de patrulha devem ser um pouco difíceis de prever (CHEN; CHENG; WISE, 2017).

Na atividade de rotina de prevenção, as patrulhas policiais realizam rotas. Cada rota corresponde a um ciclo simples que contém uma origem e um destino e representa a sequência de visitas realizadas pela patrulha que percorre a rota. O custo e o tempo de uma rota são obtidos pela soma dos custos e tempos dos arcos que formam o ciclo. Neste sentido, a ação de patrulhamento ou policiamento é definida como deslocamento em rotas estabelecidas e controladas, exercendo a fiscalização em determinado território (BERNÁBE LORANCA *et al.*, 2017).

Convém destacar que, em contraste com os modelos clássicos de roteamento de veículos, as aplicações do mundo real incluem duas dimensões importantes – evolução e qualidade da informação (PILLAC *et al.*, 2013). Em especial no problema de roteamento de patrulhas policiais, identifica-se a evolução, pois as informações disponíveis ao planejador sofrem alterações, como, no caso, do surgimento de novos chamados de emergência a serem atendidos. A qualidade da informação reflete

incertezas, presentes na probabilidade de uma ocorrência policial ser revelada no *hotspot*, considerando o local, o horário e o dia da semana esperados.

Neste horizonte, a classificação dos problemas de roteamento de patrulhas policiais entre estáticos ou dinâmicos, e determinísticos ou estocásticos, pode contribuir na compreensão da matéria. Em problemas estáticos e determinísticos, todas as entradas são conhecidas de antemão e as rotas dos veículos não mudam quando estão em execução. Problemas estáticos e estocásticos são caracterizados por entradas parcialmente conhecidas como variáveis aleatórias, cujas realizações só são reveladas durante a execução das rotas. Em problemas dinâmicos e determinísticos, parte ou toda a entrada é desconhecido e revelado dinamicamente durante o desenho ou execução das rotas. Problemas dinâmicos e estocásticos têm parte ou a totalidade sua entrada é desconhecida e revelada dinamicamente durante a execução das rotas, mas em contraste com a última categoria, o conhecimento estocástico explorável está disponível nas informações reveladas dinamicamente (PILLAC et al., 2013).

Menezes et al (2014) apresentam modelo de roteirização de rondas preventivas realizadas por uma Guarda Municipal da Região Metropolitana de Salvador, na rede de ensino pública municipal, de natureza determinística e estática, com base no Problema do Caixeiro Viajante (PCV) associado à metodologia *Analytic Hierarchy Process* (AHP), conforme proposta realizada por Chanta e Sangsawang (2005). Por meio da AHP, são estabelecidos pesos e níveis de preferência para alternativas em processo de decisão. O PCV pode ser compreendido como a determinação do caminho hamiltoniano de custo mínimo de um Grafo  $G$ , descrito como  $G = (V, A)$ , onde  $V = \{1, \dots, n\}$  é o conjunto de vértices,  $A = \{(i, j) | i, j = 1, \dots, n\}$  é um conjunto de arcos ligando esses vértices, associado um custo  $c_{ij}$  para os arcos. Neste sentido, o PCV é utilizado para encontrar o caminho menos custoso, conforme pesos determinados aos arcos, conforme metodologia AHP.

Saint-Guillain, Paquay e Limbourg (2021), diferentemente de Menezes, na sua formulação, apresentam Problema de Roteamento de Veículos Estático e Estocástico com Requisições Aleatórias (SS-VRP-R). Sempre que alguma informação é revelada, a solução atual é ajustada aplicando uma estratégia de recurso. Em vez de reotimizar *online*, uma estratégia de recurso pré-definida estabelece a forma como as solicitações são tratadas sempre que ocorrem. Com base nas informações

probabilísticas, busca-se uma solução de primeiro estágio que minimize seu custo *a priori*, mais a soma esperada das penalidades causadas pela estratégia de recurso.

Rumi, Shao e Salim (2020) apresentam formulação de problema para o planejamento dinâmico e estocástico de rotas de patrulhamento policial, combinando a previsão de eventos criminais, usando mobilidade humana e resposta a incidentes em tempo real. Para tanto, aplica algoritmo guloso baseado na previsão e prioridade da chamada de emergência para uma patrulha policial. Os *hotspots* são ponderados com grau de prioridade de 1 a 5, conforme a densidade de crimes no local nos últimos 30 dias, e sobre a taxa de novas ocorrências nos 7 dias passados, considerando o dia da semana, o horário e a estação do ano. A função importância verifica o *hotspot* mais indicado para visita, considerando a recompensa de polícia calculado sobre o peso do *hotspot* a ser visitado, dividido pela distância de deslocamento até ele. Em caso de ocorrência policial, o *hotspot* do local do evento se torna prioritário. A função objetivo é encontrar uma rota de patrulha que maximiza a recompensa em um custo mínimo.

Li et al (2011) utilizam o método de entropia cruzada (*cross entropy* - CE) para transformar problema de natureza determinística para estocástica. O método possui duas fases: (1) gerar uma amostra de dados aleatórios de acordo com um mecanismo específico; (2) atualizar os parâmetros do mecanismo aleatório para produzir uma amostra "melhor" na próxima iteração. Para a estimativa de rotas de patrulha, a primeira fase do método CE envolve gerar rotas de patrulha aleatoriamente selecionando bordas com base em uma matriz de transição inicial. Esta matriz define os benefícios de viajar entre quaisquer dois nós. A matriz inicial geralmente assume que viajar entre diferentes arestas resulta em benefícios iguais. Na segunda fase, a matriz de transição é atualizada com base nos verdadeiros benefícios calculados de viajar entre as arestas selecionadas. Essa abordagem pode considerar a natureza dinâmica dos eventos criminais.

Xu Chen e Yum (2010), no mesmo sentido, propõem um algoritmo entropia cruzada para soluções rápidas e quase ótimas. Para o desenho da estratégia de patrulha aleatória, introduzem o conceito de entropia para avaliar a aleatoriedade e propor a estratégia de escalonamento de rotas de patrulha de máxima entropia. O primeiro passo é a identificação dos *hotspots* e as estruturas notáveis no ambiente. Depois que a previsão da tendência do crime é feita, a distribuição esperada do crime nas dimensões espacial e temporal é especificada. Com base nisso, é gerada uma

rota de patrulha que maximiza a eficácia da patrulha em um horizonte de planejamento desejado (por exemplo, um turno de patrulha de 8 horas). Quando informações importantes são recebidas e a previsão precisa ser atualizada, o procedimento é repetido para gerar uma rota de patrulha atualizada.

Ruan et al (2005) dedicam-se a modelo de patrulhamento estocástico. A partir de um grafo, há um conjunto finito de nodos de interesse, cada qual com atributos de localização fixa, taxa de incidentes por hora, usando a distribuição de Poisson e índice de importância. As arestas ponderadas conectam os nodos. E há um conjunto de finito de patrulhas com velocidade estabelecida para o cobrimento dos nodos. Os nós são agrupados em setores, ficando uma viatura responsável pelo patrulhamento em cada um deles. Para cada setor, fixa-se uma estratégia de resposta preventiva de chamada de serviço e projeta-se várias rotas de patrulha off-line. A unidade de patrulha seleciona aleatoriamente rotas predefinidas para realizar patrulhamento preventivo; sempre que uma solicitação de chamada para serviço é recebida, a unidade de patrulha para a patrulha atual e responde à solicitação imediatamente; após completar a chamada para o serviço, a unidade de patrulha retoma a rota de patrulha suspensa. O planejamento de rotas *off-line* para cada setor é formulado como um Processo de Decisão Markoviano de horizonte infinito. O método permite gerar múltiplas rotas satisfatórias, de forma a conferir presença virtual e imprevisibilidade ao patrulhamento.

Reis et al (2006) apresentam um modelo algoritmo genético customizado, empregado para lidar com o projeto de rotas de patrulha ótimas e suas questões associadas, fazendo uso do modelo de simulação multiagente. É estabelecido um conjunto de metas, cada uma relacionada a coordenadas físicas, relativas aos pontos sensíveis para ocorrência de crimes. Há um conjunto de equipes de patrulhamentos e um conjunto de rotas de patrulha. O objetivo é minimizar o número de crimes num dado momento observado. A solução inicial é estabelecida aleatoriamente. O valor de ajuste de cada cromossomo (conjunto de rotas) é calculado tomando como base o número médio de crimes cometidos em execuções de simulador multiagente. Desta forma, as rotas geradas possuem certo grau aleatoriedade, em razão do uso do algoritmo genético, mas as informações sobre os pontos a serem patrulhados são conhecidos previamente.

As estratégias de pesquisa operacional, tais como o Problema do Caixeiro Viajante, Árvores Geradoras Mínimas e Particionamento de Grafos podem ser utilizadas no problema de roteamento de patrulhas policiais. Contudo, Chen, Cheng e

Wise (2017) criticam a adoção dessas estratégias, em razão de suas naturezas determinísticas, o que permitiria mais facilmente aos criminosos inteligentes prever as rotas de patrulha e aproveitar o tempo ocioso entre as visitas dos patrulheiros. Além disso, os ciclos de Hamilton e outros algoritmos têm alta complexidade computacional e são difíceis de generalizar para um grande número de alvos, assim como, de realizar recálculos das rotas de patrulha se o número de patrulhas mudar devido a uma resposta de emergência. Quanto ao uso de estratégias como o aprendizado por reforço e o método de entropia cruzada, afirmam ser de natureza muito complexa, portanto, embora sejam adequadas para projetar rotas de patrulha para um único patrulheiro, é difícil estendê-las para patrulhas cooperativas com vários patrulheiros (CHEN; CHENG; WISE, 2017).

Como foi possível observar, o Problema de Roteamento de Patrulhas Policiais possui várias abordagens distintas. O estudo sobre a evolução e a qualidade das informações disponíveis no sistema possibilita a escolha do modelo que melhor se adequa a situação imposta. Na próxima seção será tratada da estratégia multiagente, a qual pode ser adotada, após adaptações, para solução do problema em discussão.

## 2.2 PROBLEMA DE PATRULHAMENTO MULTIAGENTE

Pensado para área de robótica e afins, o patrulhamento multiagente pode ser aplicado no patrulhamento policial. Distintos métodos têm sido desenvolvidos por pesquisadores, envolvendo conceitos da probabilidade (CHEN; CHENG; WISE, 2015). A tarefa é coordenar eficientemente uma quantidade arbitrária de agentes em ordem de minimizar alguma métrica de desempenho associada à tarefa de patrulhamento (WIANDT; SIMON, 2018).

Os sistemas multiagentes fazem parte de uma subárea da Inteligência Artificial que visa fornecer, tanto princípios para construção de sistemas complexos envolvendo múltiplos agentes, quanto mecanismos para coordenação de comportamentos de agentes independentes. Os sistemas multiagentes são indicados se houver diferentes pessoas ou organizações com distintos (possivelmente conflitantes) objetivos e informações proprietárias, necessitando-se lidar com suas interações. Um agente é uma entidade, como um robô, com objetivos, ações e

conhecimento de domínio, situado em um ambiente. A maneira como ela age é chamada de “comportamento” (STONE; VELOSO, 2000).

Mesmo em domínios que poderiam usar sistemas que não são distribuídos, existem várias razões possíveis para usar os sistemas multiagente. Ter vários agentes pode acelerar a operação de um sistema fornecendo um método para computação paralela. Por exemplo, um domínio que é facilmente dividido em componentes – várias tarefas independentes que podem ser tratadas por agentes separados – pode se beneficiar de tal sistema. Além disso, o paralelismo dos sistemas multiagente pode ajudar a lidar com as limitações impostas por requisitos de raciocínio limitados no tempo ou no espaço (STONE; VELOSO, 2000).

Robustez é um benefício de sistemas multiagentes que possuem agentes redundantes. Se o controle e as responsabilidades forem suficientemente compartilhados entre diferentes agentes, o sistema pode tolerar falhas de um ou mais agentes. Outro benefício dos sistemas multiagentes é sua escalabilidade. Como eles são inerentemente modulares, deve ser mais fácil adicionar novos agentes a um sistema multiagente do que adicionar novos recursos a um sistema monolítico (STONE; VELOSO, 2000).

No problema apresentado neste trabalho, os agentes são as patrulhas policiais em um ambiente determinado no tempo (minuto a minuto) e espaço (área territorial), que apresentam características diferentes de comportamento (jornadas de serviço, velocidades de patrulhamento e áreas de atuação específicas). Tais recursos são suscetíveis ao empenho em atendimento de ocorrências policiais, afastando-se eventualmente dos locais em que deveriam estar patrulhando, gerando a necessidade de cobertura por outra patrulha.

Destaca-se que os agentes atuarão em ambiente de incerteza sobre os efeitos de suas ações para o ambiente. Também podem ser incertas as decisões dos outros agentes, as quais podem ocorrer ao mesmo tempo (VLASSIS, 2007). Neste sentido, as ações e as estratégias devem ser estabelecidas para escolha dos próximos passos pelos agentes de forma a atingirem seus objetivos. Assemelha-se a um jogo, onde os agentes agem de forma colaborativa.

De fato, o patrulhamento é o ato de caminhar ao redor de uma área para protegê-la ou supervisioná-la. O patrulhamento pode ser útil para domínios onde é necessária vigilância, inspeção ou controle distribuído (ALMEIDA et al., 2004). O ato de patrulhar também pode ser visto como a tarefa de percorrer um ambiente

repetidamente com o propósito contínuo de atualização de informações (FU; ANG, 2009). E sob o enfoque de atividade policial, o patrulhamento preventivo consiste em percorrer uma área, com as unidades de patrulha verificando ameaças, tentando evitar incidentes e interceptando quaisquer ameaças em andamento (RUAN et al., 2005).

A tarefa de patrulhamento pode ser classificada conforme o tipo de problema a ser solucionado por meio dela. No problema de detecção, o objetivo é detectar algum alvo (objeto ou pessoa) que esteja localizado no ambiente, como, por exemplo, encontrar uma criança perdida num centro comercial; resgatar pessoas em situação de perigo; localizar objetos tais como terroristas, guardas, reféns ou explosivos; impedir a disseminação de um dado *worm* em redes de computadores; ou detectar um invasor de uma área proibida. Já no problema da supervisão, o objetivo da patrulha é fazer a vigilância de uma determinada área onde possam ocorrer alguns eventos como, por exemplo, surgimento de ofertas especiais nos mercados eletrônicos; ocorrências de crimes numa cidade; falhas em redes de computadores; surgimento de focos de doenças numa cidade; ou modificações ou surgimento de páginas *web* (ALMEIDA, 2003).

No patrulhamento de supervisão pode-se identificar dois tipos básicos de eventos: temporários ou perduráveis. Os primeiros só podem ser observados em um determinado intervalo de tempo, como é o caso de alguns crimes contra o patrimônio, como furtos e roubos. Se a vítima não permanecer no local, aguardando a polícia, não será possível a sua localização e conseqüentemente seu atendimento. Diferentemente dos últimos, os perduráveis podem ser observados a qualquer momento a partir do instante em que ele ocorreu, tais como, um homicídio em que o corpo da vítima no local indicará a ocorrência do crime.

Em se tratando do problema da patrulha, consideramos que a percepção de cada agente consiste num campo de visão de raio  $R$ . Um valor de  $R = 0$ , o agente só percebe o lugar onde está situado. Já quando  $R \rightarrow \infty$  a percepção é global, ou seja, o agente consegue enxergar todo o ambiente (ambiente acessível). Valores intermediários de  $R$  permitem ao agente visualizar apenas determinadas regiões do ambiente (ALMEIDA, 2003). Neste ponto, observa-se aqui que o campo de percepção é o da visão humana do agente, considerando o local onde se encontra. Contudo, a troca de mensagens entre os agentes pode aumentar tal percepção. O despacho de



uma patrulha para atendimento de uma ocorrência é sabido por todas as patrulhas por meio do sistema de radiocomunicação.

Ressalta-se que o modelo de observação pode ser estocástico para uma instância de distribuição de probabilidade  $p(s_t, \phi_t)$ , onde  $s_t$  é um dado estado em algum passo de tempo  $t$  e  $\phi_t$  a observação de um agente no tempo  $t$ . Isto implica que a corrente observação  $\phi_t$  não revela completamente o verdadeiro estado do mundo, mas cada estado  $s_t$  é um estado verdadeiro (com  $0 \leq p(s_t, \phi_t) \leq 1$  e  $\sum_{s_t \in S} p(s_t, \phi_t) = 1$ ). Busca-se uma variável randômica para todos os valores de  $S$ . A probabilidade  $p(s_t, \phi_t)$  pode ser calculada da antecedente distribuição  $p(s_t)$  usando a regra de Bayes (VLASSIS, 2007):

$$p(s_t, \phi_t) = \frac{p(\phi_t, s_t)p(s_t)}{p(\phi_t)} \quad (1)$$

No patrulhamento multiagente pode estar presente a comunicação entre os agentes. A comunicação pode ser via *flags*, *blackboard* ou por mensagens. Na comunicação via *flags* ou bandeiras, os agentes colocam bandeiras no ambiente, correspondente à mensagem que ficará disponível para os demais agentes. O conceito fundamental de comunicação baseada em *blackboard* é o uso de estruturas de dados compartilhadas (por exemplo, em um centro de comando e de controle) que são acessíveis a todos os agentes. Na comunicação via mensagens, existe a possibilidade de um canal direto entre os agentes, os quais podem se comunicar através da troca de mensagens (ALMEIDA, 2003). Além disso, um aspecto fundamental na coordenação do movimento multiagente é o uso de um coordenador central, que escolhe o nó objetivo de cada agente (cognitivo), ou um descentralizado, onde a coordenação emerge da interação do agente (GOOS; HARTMANIS; VAN LEEUWEN, 2003).

No caso do patrulhamento policial, os agentes podem trocar mensagens e gerar leituras de geolocalização pelo sistema de radiocomunicação. Além disso, todas as manobras no terreno são informadas via rádio para uma central, responsável pela gestão dos recursos disponíveis. Neste sentido, os agentes podem saber dos movimentos dos demais, assim como, trocar mensagens entre si. Desta forma, para cobrir efetivamente toda a área dos *hotspots*, o patrulhamento policial requer cooperação entre os patrulheiros.

O patrulhamento poderá se dar em ambiente discreto ou contínuo. Se existe um número limitado de percepções e ações possíveis no ambiente, dizemos que ele é discreto. Caso contrário, classificamos o ambiente como sendo contínuo. O patrulhamento de uma cidade se enquadra neste último, considerando a grandeza de estados e ações no terreno (ALMEIDA, 2003).

Além disso, o ambiente de patrulhamento policial é dinâmico. No de natureza estática, somente as posições dos agentes mudam (ALMEIDA, 2003). Contudo, num cenário real de uma cidade, os pontos a serem patrulhados mudam ao longo do horário, dia da semana e mês, considerando a concentração dos crimes no tempo e espaço, dada pelos *hotspots*. A velocidade de deslocamento, nos vários processos de patrulhamento (a pé, a cavalo, de bicicleta, de viatura, com drone) alterará o tempo necessário para percorrer o espaço entre os pontos. Ademais, as ocorrências que surjam para atendimento ou eventos no trânsito (interrupções, congestionamentos etc) podem alterar o caminho e o tempo de deslocamento dos agentes. Numa representação do ambiente usando grafos, isso se reflete na mudança dos nós e das arestas ao longo do tempo.

Utilizando-se a técnica de esqueletonização (ALMEIDA, 2003), a área a ser policiada é representada por um grafo  $G = (V, E)$ , onde  $V = \{1, \dots, n\}$  é um conjunto de nós e  $E \subseteq V^2$  o conjunto de arestas de  $G$ . Para cada aresta  $(i, j)$  corresponderá um peso  $c_{ij}$ , representando a distância para percorrer entre os nodos. O movimento das patrulhas seguirá uma estratégia pré-determinada.

A estratégia de um agente é uma função  $\pi: \mathbb{N} \rightarrow V$ , tal que  $\pi(j)$  é o  $j$ -ésimo nó visitado pelo agente. Seja  $r$  agentes patrulhas em um grafo  $G$  de acordo com a estratégia multiagente. Uma estratégia multiagente  $\Pi = \{\pi_1, \pi_2, \dots, \pi_r\}$  é simplesmente definida como um conjunto de  $r$  estratégias de agente.

Destaca-se a estratégia, dentre os algoritmos estudados de patrulhamento multiagente, de minimizar o tempo entre passagens pelo mesmo lugar ou por todos os pontos, chamada de ociosidade (ALMEIDA, 2003; CHEVALEYRE; SEMPÉ; RAMALHO, 2004; FU; ANG, 2009), no caso os *hotspots*. A ociosidade de um nodo  $i$  no tempo  $t$  é o somatório do tempo decorrido desde que o nó tenha recebido a visita de um agente. A ociosidade de todos os nós no início do patrulhamento é 0. A pior ociosidade é o maior valor de ociosidade ocorrido durante o o processo de patrulhamento para todos nós. A escolha do próximo vértice a ser visitado pode ser

Reativo Consciente, cujo próximo nó a ser visitado é aquele com maior ociosidade individual de sua vizinhança; ou Cognitivo Coordenado, cujo próximo nó a ser visitado é aquele com maior ociosidade compartilhada de todo o grafo, conforme sugestões dadas por um coordenador central. Este coordenador é responsável por evitar que mais de um agente escolha o mesmo próximo nó (ALMEIDA et al., 2004).

Reis et al (2006) utilizam a estratégia multiagente para simular o emprego de patrulhas policiais. Além do grupo de agentes policiais, interagem no sistema proposto um conjunto de atores que frequentemente tentam cometer crimes. A visão do criminoso é limitada a células de uma grade com tamanho determinado. Há uma quantidade constante de criminosos. Diferentemente dos policiais, os delinquentes possuem capacidades diferentes, o que determina a seleção de locais e alvos para cometer crimes, assim como, níveis de periculosidade (iniciante, intermediário e perigoso). O objetivo do criminoso é localizar o alvo mais próximo no mapa, cuja decisão de cometer ou não o crime é condicionada a presença de agente policial.

Chen, Cheng e Wise (2015) formulam problema de roteamento de patrulhas policiais, voltadas para o processo a pé, com estratégia multiagente, com vistas ao policiamento da rede viária de uma cidade, empregando no processo de decisão a estratégia bayesiana e o algoritmo de colônia de formigas. Os patrulheiros se movem na rede rodoviária e se comunicam frequentemente com o centro de controle. Toda vez que um patrulheiro termina de patrulhar um *hotspot*, ele envia uma mensagem para o centro de controle, e o centro de controle calcula e envia de volta a posição do próximo hotspot. Os patrulheiros têm um mapa *a priori* do ambiente e sempre viajam para o próximo *hotspot* pelo caminho mais curto. A principal métrica utilizada é a da ociosidade, a fim de registrar o tempo desde a última visita. O algoritmo de colônia de formigas é usado para registrar o histórico de visitas das patrulhas aos *hotspots*, por meio da análise da presença de feromônio em decorrência de processo de depósito e decaimento, pela presença e ausência da patrulha policial, respectivamente. A estratégia bayesiana é usada na decisão do movimento de um dado patrulheiro para qualquer outro *hotspot*, considerando as visitas anteriores, distância percorrida, coordenação entre patrulheiros e outros fatores. O objetivo principal é minimizar o tempo de ociosidade do conjunto de *hotspot*.

Na próxima seção se discutirá os mecanismos para determinação dos *hotspots*, os quais servirão de base para a escolha dos locais de patrulhamento pelas equipes de policiais.

## 2.3 DEFINIÇÃO DE HOTSPOTS

O crime não ocorre uniformemente em toda a cidade. Em vez disso, concentra-se em lugares relativamente pequenos que geram mais da metade de todos os crimes (BRAGA, 2005; ECK; WEISBURD, 2015). Desta forma, muitos problemas de criminalidade podem ser reduzidos mais eficientemente se os policiais concentrarem sua atenção nesses lugares desviantes (WEISBURD et al., 2003).

O uso de técnicas e *software* de análise de crimes pode permitir o planejamento tático de curto prazo (por exemplo, quais bairros patrulhar nas próximas horas e dias) e esforços estratégicos de longo prazo (por exemplo, programas de intervenção no mercado de drogas que reabilitam infratores não violentos em primeiro mandato) (GODWIN; STASKO, 2017). Tanto isso é verdade que o mapeamento de pontos se tornou uma técnica analítica popular usada por agências policiais, com vistas à redução de crimes, permitindo a identificação visual de onde o crime tende a ser mais alto, auxiliando na tomada de decisões no direcionamento e implantação de recursos (CHANEY; TOMPSON; UHLIG, 2008).

De acordo com a teoria das atividades rotineiras, o crime não ocorre aleatoriamente no tempo e no espaço, mas é produzido pela convergência no tempo e no espaço de criminosos motivados, alvos adequados e ausência de guardiões capazes. Essa convergência, por sua vez, é afetada por fatores como atividade diária e padrões de tráfego, organização comunitária e desenvolvimento de várias formas de tecnologia (COHEN; FELSON, 1979). Neste sentido, *hotspots* e suas pontuações são determinados usando uma combinação de experiência de domínio, *feedback* de patrulhas e eventos recentes. Juntamente com a malha viária, as pontuações definem o gráfico ponderado, que é a principal entrada do método (CHAWATHE, 2007).

Como visto, não só os dados do histórico de ocorrências de uma dada região podem ser considerados no estudo dos *hotspots*. O uso de diferentes tipos de dados, que não estão diretamente relacionados ao crime, pode aumentar a precisão dos modelos, e informações de regiões distantes da cidade podem fornecer diretivas sobre atividades criminosas de outra parte da cidade (DASH; SAFRO; SRINIVASAMURTHY, 2018). Observa-se que as abordagens reativas, centradas na ideia que o crime sempre ocorrerá exatamente onde ocorreu no passado, afastam-se

da percepção de risco ou potencial de crime (CAPLAN; KENNEDY; MILLER, 2011). Deve-se estabelecer um paralelo com as quatro dimensões do crime – legal, criminoso, vítima e importância do lugar – as quais podem descrever uma discreta localização de onde o crime pode ocorrer no tempo e no espaço (BOTTOMS; WILES, 2020).

A distribuição de infratores, alvos (possíveis vítimas) e policiais ao longo do tempo e do espaço influem nos padrões de manifestação dos eventos criminais. Mudanças na sociedade podem aumentar o número de alvos potenciais, ao mesmo tempo, que os separam das pessoas que podem protegê-los (policiais, amigos, parentes etc.). A busca de alvos pelos infratores é influenciada por características pessoais (como sexo, idade, raça, experiência e tipos de crime) e a distribuição dos alvos do crime no terreno. Delinquentes razoavelmente racionais, enquanto se envolvem em suas atividades rotineiras, notam lugares sem proteção e onde é improvável que protetores apareçam. Além disso, trabalhos recentes direcionam a atenção policial não somente para os locais com maior densidade de crimes, mas também facilidades instaladas nos espaços a serem policiados. Cita-se, como exemplo, as escolas, tavernas, lojas de conveniência, igrejas, prédios de apartamentos e projetos de habitação pública. Diferentes tipos de instalações têm o condão de contribuir para o aumento ou diminuição do crime em seu ambiente imediato (ECK; WEISBURD, 2015).

Brantingham e Brantingham (1995) vão além. Trabalham com a classificação dos ambientes urbanos sobre quatro enfoques, quanto ao potencial para ocorrência de crimes:

- Geradores de crimes: são áreas específicas onde um grande número de pessoas é atraído por razões não relacionadas a qualquer nível específico de motivação criminosa que possam ter ou a qualquer crime específico que possam acabar cometendo. Exemplos típicos podem incluir áreas de compras; distritos de entretenimento; concentrações de escritórios; ou estádios esportivos.
- Atratores de crimes: são lugares, áreas, bairros, distritos particulares que criam oportunidades criminosas bem conhecidas para as quais criminosos intencional e fortemente motivados são atraídos por causa

das oportunidades conhecidas para tipos específicos de crimes. Exemplos podem incluir distritos de bares; áreas de prostituição; mercados de drogas; grandes shopping centers, principalmente aqueles próximos às principais bolsas de transporte público; estacionamentos grandes e inseguros em áreas comerciais ou comerciais.

- Locais neutros para o crime: não atraem criminosos intencionais nem produzem crimes, criando oportunidades criminosas que são tentadoras demais para resistir. Em vez disso, eles sofrem crimes ocasionais cometidos por membros locais.
- Geradores de medo: parecem estar relacionados a cinco grandes categorias— medo direto de outra pessoa, medo de ficar sozinho, medo à noite, no escuro, medo em áreas desconhecidas, medo de encontros com pessoas assustadoras. O medo do crime é um medo geral de ser atacado, de sofrer algum dano físico, de sofrer uma intrusão que destrói a privacidade e a dignidade.

Desta forma, uma série de características são levantadas para análise espaço-temporal do crime (PERRY et al., 2013):

- Hora do dia, dia da semana, e hora e dia ciclos;
- Proximidade temporal de outros eventos (por exemplo, dia de pagamento, eventos esportivos, concertos);
- Estação do ano;
- Clima;
- Intervalo entre ofensas em crimes em série;
- Repetição de locais;
- Progressão geográfica de incidentes em crimes em série;
- Espacial arranjo de incidentes;
- Tipo local (por exemplo, estacionamentos, lojas de conveniência, casas locadas pelo poder público para populações vulneráveis);
- Correlatos geográficos (por exemplo, perto de pontos de ônibus, perto de estabelecimentos licenciados para vender bebidas alcoólicas);
- Fatores ambientais e alvos (por exemplo, iluminação, condição da vizinhança, nível de tráfego)

- Dados demográficos e econômicos da área do crime.

Neste sentido, Caplan, Kennedy e Miller (2011) trabalham com a ideia de que os lugares podem ser avaliados em termos de graus variados de risco criminogênico em relação a outros lugares próximos ou distantes. Enquanto um evento de crime ocorre em um local finito, o risco é um valor dinâmico contínuo que aumenta ou diminui a intensidade e se agrupa ou se dissipa em diferentes lugares ao longo do tempo, mesmo em locais distantes de um evento de crime. As avaliações de risco estão ligadas à geografia e, em relação ao crime, os valores de risco são a medida do potencial de um local para que um evento de crime ocorra. O risco geográfico é determinado por um nexo de certos fatores e só muda à medida que as características e interações desses fatores variam.

É importante destacar a crítica de Block (1993) quanto à análise da densidade de crimes sobre áreas arbitradas, como circunscrição de estruturas policiais e políticas. Tal análise não seria capaz de lidar com áreas densas reais cruzando as linhas de limite, ocorrendo ao longo de uma linha de limite ou ocorrer em áreas pequenas, mas concentrada dentro do limite arbitrário. Refere-se a tal formato como falácia de unidade de área, onde as características agregadas de uma área geral são erroneamente aplicadas a cada seção ou vizinhança dentro da área. Quanto aos mapas de pinos, com os locais de infrações, acidentes de trânsito ou endereços de infratores conhecidos, afirma que podem fornecer uma riqueza de informações, e existem métodos estatísticos para organizar essas informações de forma útil. No entanto, as distribuições de frequência do mapa de pinos ou dados de endereço, por si só, não podem definir uma área densa de hot spot. Um único endereço com mais crimes do que qualquer outro endereço pode ou não estar localizado na área de crime de maior densidade no mapa.

Por outro lado, áreas com baixa concentração de crimes também devem ser alvo da ação policial. Tayebi et al (2014), por exemplo, busca determinar ações voltadas para os *coldspots*, que cobrem uma área muito mais ampla do que os *hotspots*. O policiamento direcionado não é viável para a prevenção do crime nessas áreas. A distribuição espacial dos incidentes criminais em pontos frios é essencial para as estratégias de intervenção. Enquanto, na análise de *hotspots* o foco está na modelagem do surgimento e evolução dos *hotspots*, na análise de *coldspot* para

detectar o comportamento espacial dos infratores, precisa-se de um modelo que seja flexível para ser personalizado para cada infrator (TAYEBI et al., 2014).

Infelizmente, existem muitas versões de definições para o termo *hotspots* e não há consenso sobre a melhor definição para focos de crime (LI et al., 2011). O maior desacordo na definição de *hotspot* é sobre agregar dados usando diferentes unidades espaciais. Neste sentido, identifica-se na literatura várias técnicas de mapeamento diferentes usadas para identificar os *hotspots* – mapeamento de pontos, mapeamento temático de áreas geográficas (por exemplo, áreas de censo), elipses espaciais, mapeamento temático de grade e estimativa de densidade do *kernel*. Essas técnicas podem ser tão simples quanto representar cada evento de crime como um ponto e observar a distribuição geográfica desses pontos; utilizar funções dentro de um sistema de informação geográfica (GIS) para áreas administrativas de sombra temática (por exemplo, zonas de censo ou batidas policiais); ou representando a distribuição do crime como uma superfície contínua que se relaciona com as densidades volumétricas da distribuição geográfica do crime (CHAINEY; TOMPSON; UHLIG, 2008).

Koper (1995) define *hotspot* como um conjunto de endereços que juntos produziram 20 ou mais ligações de crimes graves (por exemplo, roubo, estupro, arrombamento) e 20 ou mais ligações de crimes leves (por exemplo, distúrbios, prostituição) ao longo de um ano. Tais pontos devem corresponder a locais onde o crime ocorre em público (ou seja, locais públicos ou locais com transbordamento de atividade para ruas ou estacionamentos) para que a presença da polícia possa razoavelmente ter um efeito dissuasor. Os limites dos *hotspots* são definidos de modo que cada *hotspot* não fosse maior do que um quarteirão linear padrão, nenhum *hotspot* estivesse a um quarteirão de outro *hotspot* e cada *hotspot* pudesse ser visto inteiramente a partir de um epicentro.

Li (2011) traz o conceito de autocorrelação espacial, o qual é frequentemente observado em dados criminais. A análise de autocorrelação espacial consiste em um conjunto de estatísticas que descrevem como uma variável (por exemplo, probabilidade de crime) é autocorrelacionada através do espaço. O autor usa a função  $G_i^*$  (GETIS; ORD, 2010), conhecida como *Hot Spot Analysis*. É comumente usada para detectar *clusters* espaciais da magnitude de um atributo. É uma medida



multiplicativa da associação espacial geral de valores que caem dentro de uma distância crítica um do outro.

Ratcliffe (2002) trata das dificuldades na classificação temporal dos crimes. O exato momento da ocorrência nem sempre é conhecido. Nos crimes de arrombamento de residências, as vítimas tomam ciência apenas da ocorrência quando retornam aos seus lares. Nos furtos de veículos só se sabe da ocorrência do fato, após a falta na localização do bem. Afirma que na maioria dos crimes o momento da ocorrência está mais relacionado com a rotina da vítima. Alguns estudos usam o ponto médio entre o início e o término da ocorrência como referência para o momento do crime. Pela análise aorística, o tempo do crime é estabelecido após a investigação que calcula a probabilidade de um evento ocorrer dentro de determinados parâmetros temporais e soma as probabilidades de todos os eventos que possam ter ocorrido para produzir um peso temporal em uma determinada área.

Para definição dos *hotspots*, Yassen et al (2018) dividem as prioridades dos *hotspots* em três níveis: alto, médio e baixo. *Hotspot* com alta prioridade deve ser visitado 3 vezes, enquanto *hotspot* com prioridade média e baixa devem ser visitados 2 e 1 vez, respectivamente. Assim, os *hotspots* são definidos não apenas com sua localização na cidade, mas também com o tempo em que se tornam “quentes” e o nível de prioridade de cada *hotspot*. Contudo, não fica esclarecido como é definida a ponderação para o estabelecimento das prioridades.

Algumas técnicas são direcionadas a tentar identificar características geográficas que contribuem para o risco do crime (por exemplo, lojas de bebidas, bares, tipos de vias) e fazer previsões sobre o risco do crime baseadas sobre quão perto de tais locações há uma indução a riscos (PERRY et al., 2013). Neste sentido, Caplan, Kennedy e Miller (2011) propõem a modelagem de terreno de risco (*Risk Terrain Model* - RTM). A técnica busca identificar, por meio de meta-análise ou outros métodos empíricos, revisão de literatura, experiência profissional e conhecimento do profissional, todos os fatores que estão relacionados a um resultado específico para o qual o risco está sendo avaliado. Em seguida, padroniza-se cada fator para uma geografia comum. Essencialmente, o RTM atribui um valor (ponderado ou não ponderado) que significa a presença, ausência ou intensidade de cada fator em todos os lugares ao longo de uma determinada geografia. Cada fator é representado por um

mapa de cobertura separado da mesma geografia. Quando todas as camadas do mapa são combinadas em um Sistema de Informações Geográficas (GIS), elas produzem um mapa composto – um mapa de terreno de risco – onde cada lugar ao longo da geografia recebe um valor de risco composto que considera todos os fatores associados ao resultado específico do crime.

Perry et al (2013) relacionam os métodos mais comumente usados para estabelecer os *hotspots*. Cita o método de mapeamento de *grid* para a identificação dos *hotspots*. A área em estudo é dividida em células com 350 metros de comprimento. Qualitativamente, o mapa de grade tem um bom “ruído”. As células destacadas mostram padrões claros, mas há variação na localização das células coloridas, e pontos quentes isolados são comuns. *Hotspots* podem ser identificados mapeando instâncias de crimes e encontrando um conjunto de elipses que cobrem os agrupamentos de ocorrências. Muitas vezes, as elipses incluem muitas áreas que não são realmente de alta criminalidade porque manchas não formam naturalmente elipses perfeitas. Outro método é de Estimativa de Densidade do Kernel (*Kernel Density Estimation* - KDE) para identificar *hotspots*. A ideia intuitiva é distribuir a contribuição esperada de cada crime para o risco de crime futuro em uma determinada área usando uma função matemática chamada *kernel*. O KDE é uma abordagem de análise estatística usada para interpolar uma superfície contínua de dados criminais com base em pontos de dados criminais iniciais de diferentes locais.

Como visto a identificação de *hotspots* é comumente utilizada pela análise criminal, com vistas à priorização dos espaços mais suscetíveis à ocorrência de crimes. Não leva em consideração apenas o histórico de eventos, mas também o comportamento de autores e das vítimas, assim como, estruturas presentes nas cidades, as quais podem ser relacionadas a crimes.

Na próxima seção, passa-se ao estudo de métodos de predição de crimes, a partir dos dados coletados.

## 2.4 ANÁLISE PREDITIVA

O policiamento preventivo baseado na ideia de *hotspots* se popularizou nas estruturas policiais. Sua concepção está em olhar para o passado na busca de

inferências quanto ao comportamento futuro do crime. O policiamento preditivo está um passo à frente. Envolve a aplicação de técnicas analíticas – particularmente técnicas quantitativas – para identificar alvos prováveis para intervenção policial e prevenir crimes ou resolver crimes passados fazendo previsões estatísticas (PERRY et al., 2013).

Segundo Xu Chen (2012), os recentes avanços em instrumentos de vigilância de segurança e técnicas de processamento de informações permitem que uma abordagem preventiva, baseada na previsão da tendência do crime seja agora possível. Com as novas informações coletadas e a previsão de crimes atualizada, é necessário o estabelecimento de rotas de patrulhas condizentes com os dados disponíveis. Isso aumenta o requisito de computação em tempo real para o problema de planejamento de rotas de patrulha.

Embora o policiamento proativo seja a intenção, a realidade é que muitos policiais passarão grande parte do dia respondendo a chamadas para o 911 (190 no Brasil) que os afastam de sua localização atual, onde desenvolvem rotinas de policiamento preventivo. Os sistemas de crime preditivo podem ajudar a reduzir o tempo de resposta para essas chamadas, tentando posicionar os policiais próximos às áreas que recebem chamadas (BRAGA, 2005; GODWIN; STASKO, 2017).



**Figura 1 - O processo de negócio de policiamento conduzido por previsão de dados**

Fonte: Perry et al. (2013).

Os métodos de policiamento preditivo podem ser classificados em quatro grandes categorias: 1) Métodos para predição de crimes; 2) Métodos para predição de infratores; 3) Métodos para predição da identidade de perpetradores; 4) Métodos para predição de vítimas de crimes. O foco neste trabalho é sobre o primeiro grupo, abordagens usadas para prever locais e horários com maior risco de crime. Incluem-se neste grupo métodos voltados à identificação de áreas com risco aumentado para ocorrências de crimes, a partir do histórico de dados criminais, informações socioeconômicas e características geográficas. Os métodos envolvem processo de coleta e análise de dados criminais, os quais são combinadas com outras informações da comunidade em estudo, para enfim produzir predições. A partir delas, a polícia age por meio de intervenções. As ações podem ter o efeito de alterar o ambiente. Em razão disso, os dados são reavaliados realimentando o ciclo (PERRY et al., 2013).

Neste caminho, Almanie, Mirza e Lor (2015) estabelecem modelo preditivo para a identificação dos *hotspots*. Preliminarmente, os dados são pré-processados e classificados, conforme os seguintes tipos: agressão, embriaguez, outros crimes, desordem pública, furto e crime do colarinho branco. São criados campos relativos ao mês, dia e hora do evento criminal. Os horários dos crimes são agrupados em 6 grupos: da 1 hora às 4 horas e 59 minutos, das 5 horas às 8 horas e 59 minutos, das 9 horas às 12 horas e 59 minutos, das 13 horas às 16 horas e 59 minutos, das 17 horas às 20 horas e 59 minutos e das 21 horas à 0 hora e 59 minutos. A localização dos *hotspots* é dada pelo bairro da cidade em estudo. Em seguida, aplica três algoritmos diferentes: *A priori*, *Naïve Bayesian* e o *Árvore de Decisão*, a fim de identificar os *hotspots*.

Também em modelo preditivo, Dash, Safro e Srinivasamurthy (2018) relacionam conjuntos de dados da cidade de Chicago, incluindo: banco de dados de crimes; localização e número de visitantes de bibliotecas; localização e limites dos distritos policiais; solicitações de serviços de iluminação, de transporte público, de tapa buracos, de saneamento e informações sobre casas desocupadas; localização e média dos alunos das escolas no *American College Test*. Os dados são agrupados em 77 comunidades da cidade. Para explorar a estrutura social, cria-se um grafo com as instâncias disponíveis, estabelecendo-se arcos ponderados, conformes dados disponíveis. Para prever o número de crimes em uma determinada comunidade para

um determinado ano e mês, aplicam-se três tipos de modelos de regressão, a saber, regressão polinomial, regressão vetorial de suporte e modelo auto-regressivo.

Yu et al (2011) usa técnicas de mineração para o estabelecimento de modelo preditivo. Os dados são oriundos de diversas agências da cidade. Cada entrada é registro de um crime ou de evento relacionado. Todos os registros possuem o tipo de evento, localização (longitude e latitude), data e hora. Os dados são agregados em seis categorias, incluindo Prisão, Roubo Comercial, Execução de Dívida Imobiliária, Furto de Veículo Motorizado, Roubo Residencial e Roubo de Rua. O espaço é dividido em células quadradas, em duas resoluções de 800 e 400 metros quadrados, as quais são populadas com os dados do mês em estudo. Dois meses da base são dados como treino e um como teste. São usados nos experimentos as técnicas de vizinho mais próximo (1NN) e uma variação restrita de localização, árvore de decisão (J48), máquina de vetores de suporte (SVM) com função de base radial como o tipo de *kernel*, rede neural com rede de 2 camadas e *Naïve Bayes*.

Malik et al (2014), na análise preditiva, introduzem propriedades de sazonalidade e periodicidade do crime para fornecer previsões espaço-temporais dos níveis futuros de incidência de crimes. Para modelar dados de séries temporais, empregam a técnica de decomposição de tendência sazonal baseada em uma metodologia de regressão ponderada localmente (STL), onde um sinal de série temporal é considerado como consistindo na soma de múltiplos componentes de variação (ano, mês e dia da semana). O espaço geográfico é fragmentado em retângulos uniformes (*grids*). Para refinar ainda mais o modelo de previsão em geoespaço, utiliza a técnica de Estimativa de Densidade de Kernel (*Kernel Density Estimation* - KDE) para espalhar a probabilidade de ocorrência de incidentes para suas regiões vizinhas e a técnica de Estimativa de Densidade de Kernel de Covariância Dinâmica para redução da variação estocástica. Explora similaridade entre *grids* vizinhos por meio do cálculo de distância de semelhança entre um bloco de referência e os vizinhos que se encontram dentro de um dado raio do centroide do bloco inicial. Os horários dos eventos são categorizados, a fim de permitir o estudo por faixa horária de incidência dos crimes.

Chainey, Tompson e Uhlig (2008) introduzem o Índice de Precisão da Previsão (Prediction Accuracy Index - PAI). Este índice foi elaborado para considerar a taxa de

acerto contra as áreas onde os crimes estão previstos para ocorrer em relação ao tamanho da área de estudo. O PAI é calculado dividindo a porcentagem da taxa de acertos (a porcentagem de eventos de crime para um período de dados de medição que cai nas áreas onde os crimes estão previstos para ocorrer determinada a partir dos dados de entrada, ou seja, os *hotspots* de crimes) pela porcentagem de área (a porcentagem das áreas previstas, os *hotspots*, em relação a toda a área de estudo).

Perry et al (2013) apresentam uma série de métodos para a análise preditiva. As regressões, por exemplo, se ajustam a uma relação matemática entre a variável a ser prevista e as variáveis “explicativas” independentes. Em contraste com o mapeamento de *hotspots*, as regressões projetam o risco de crime futuro com base não apenas em crimes passados, mas também no que pode ser uma ampla gama de dados. O desafio nos métodos de regressão é seleção das variáveis de entrada. Embora se possa colocar todas as variáveis possíveis em um modelo, o resultado será um modelo com sobreajuste; as fórmulas resultantes refletem apenas ruído aleatório nos dados de entrada, em vez de uma relação verdadeira entre as variáveis de entrada e saída. Dentro do campo da mineração de dados, cita os métodos de clusterização. Tais algoritmos buscam agrupar dados em agrupamentos com atributos semelhantes. Algoritmos de clusterização espacial executados em dados de crimes geoespaciais podem encontrar *hotspots* estatisticamente significativos (como é exemplo o algoritmo Getis-Ord  $G_i^*$ ). Algoritmos de classificação procuram estabelecer regras que atribuam uma classe ou rótulo a eventos. As técnicas de classificação podem ser aplicadas a qualquer problema para o qual o analista possa usar uma previsão categórica em vez de uma numérica. Os métodos de quase repetição operam na suposição de que alguns crimes futuros ocorrerão muito próximos aos crimes atuais no tempo e no lugar. A técnica pressupõe a marcação de áreas que acabaram de presenciar um crime, especialmente um roubo, como estando em risco elevado de outro crime semelhante em um futuro próximo.

De acordo com o exposto, tem-se várias abordagens na análise preditiva. Exploram não só a localização das ocorrências policiais no passado, em face de aspectos de temporalidade, como mês do ano, dia da semana e horário do dia, mas também relações sociais presentes nos locais, no tocante a estruturas notáveis (escolas, bibliotecas, comércio etc.). Isto permite, a construção de modelos preditivos

com níveis de acerto consideráveis, o que pode alimentar os problemas de roteamento de patrulhas policiais.

## 2.5 ESTRATÉGIAS DE DECISÃO NO PATRULHAMENTO

Nas seções anteriores, foi tratado do problema do patrulhamento policial e multiagente, com vistas ao atendimento de *hotspots*, visando a aplicação de modelo preditivo criminal. Parte-se para a discussão das estratégias de patrulhamento. Neste sentido, registra-se que o policiamento por meio de patrulhas pode se dar de forma estática ou dinâmica, ou seja, através de paradas ou rondas por pontos estratégicos. Entende-se que as patrulhas policiais devem dedicar um tempo de parada nos *hotspots*, a fim de que a ação seja percebida e gere os efeitos esperados. O simples patrulhamento, por meio da passagem de viaturas policiais, por exemplo, não geraria resultados significativos para a prevenção a crimes.

Nos estudos realizados por Koper (1995) sugere-se que as viaturas realizem paradas, as quais parecem ser mais eficazes quando duram entre 13 e 15 minutos. Após 15 minutos, os benefícios de aumentar a duração diminuem, embora deva-se ser cauteloso ao interpretar esse efeito porque não é estatisticamente significativo.

Presenças mais longas podem aumentar a incerteza sobre as intenções e ações da polícia e podem aumentar a percepção de risco entre as pessoas no *hotspot*. Isso por si só pode afastar potenciais encenqueiros da área, criando um efeito residual mais duradouro. É claro que a polícia também pode remover os encenqueiros da área por contato direto. Os associados dessas pessoas também podem saber de boca em boca sobre a presença da polícia ou ações nos pontos quentes (KOPER, 1995).

Sherman (1990) teoriza um ponto de utilidade máxima para o comprimento da repressão, além do qual nenhum ganho adicional em dissuasão residual é obtido. Tal descoberta aqui implicaria uma duração ótima de presença para aumentar as percepções de risco e afastar os encenqueiros de um ponto quente. Uma vez que uma presença ultrapasse esse período, uma estadia mais longa traz poucos

benefícios adicionais. Até o momento, no entanto, não se tem base empírica para estimar onde esse limiar pode estar, se existir (KOPER, 1995).

Adotando-se o patrulhamento com paradas em pontos sensíveis (*hotspots*), uma boa estratégia para cobertura de tais pontos pelas patrulhas policiais é minimizar o tempo de ociosidade em tais locais, considerando o tempo entre visitas sucessivas (CHEN; CHENG; WISE, 2015). Isto não quer dizer que o trânsito das patrulhas entre os *hotspots* não garanta também sensação de segurança aos passantes no caminho percorrido pelos policiais. Contudo, o ganho de policiamento é estabelecido, a partir da consideração sobre a importância dos *hotspots* visitados durante a rota estabelecida.

O avanço de cada patrulha para outro *hotspot* pode ser compreendido como uma mudança de estado do agente. A definição de preferências entre os estados existentes (*hotspots*) torna-se importante para a decisão do destino de cada patrulha. Uma forma de formalizar a preferência sobre estados é atribuindo-se um número real para cada estado  $U(s)$  chamada de utilidade do estado  $s$  para um particular agente. Formalmente, para dois estados  $s$  e  $s'$  é assegurado que  $U(s) > U(s')$  se e somente se o agente prefere o estado  $s$  ao estado  $s'$ , e  $U(s) = U(s')$  se e somente se o agente é indiferente entre  $s$  e  $s'$  (VLASSIS, 2007).

Neste sentido, a literatura apresenta solução inspirada no algoritmo de colônia de formigas para esta problemática (CHEN; CHENG; WISE, 2015; FU; ANG, 2009). Combinando computação distribuída, *feedback* positivo e heurística construtiva gananciosa, o algoritmo de colônia de formigas é uma abordagem para otimização estocástica e resolução de problemas. Tem aplicação em problemas clássicos, como o do Caixeiro Viajante (DORIGO et al., 1991) e Problema de Roteamento de Veículos (TAO; CHEN; TAO, 2012). Inspira-se em fenômeno presente em espécies de insetos sociais, que coordenam as atividades dos indivíduos na colônia sem comunicação direta ou raciocínio complexo. Em vez disso, eles depositam e detectam marcadores químicos chamados feromônios em um ambiente físico compartilhado que participa ativamente da dinâmica do sistema (BRUSSEL et al., 2001). Trazendo a ideia para um mapa, esses traços de feromônio são uma indicação de quantas vezes uma célula foi atravessada. No caso, as “formigas” são constantemente atraídas para células com níveis mais altos de feromônios. Se mais de uma célula tiver a mesma quantidade de



nível de feromônio, o agente simplesmente escolhe a célula aleatoriamente (FU; ANG, 2009).

Fu e Ang (2009), em problema de patrulhamento multiagente, fazem uso da estratégia voltada a minimizar o tempo entre visitas sucessivas de importantes posições presentes em mapa. Introduzem algoritmo probabilístico da colônia de formigas, que possibilita a criação de trilhas de feromônios virtuais como uma indicação de como um mapa desconhecido foi percorrido por um grupo de agentes. Cada agente planeja seu próximo movimento de maneira probabilística com base puramente em suas informações de feromônios virtuais locais.

Como se afirmou na Seção 2.2, Chen, Cheng e Wise (2015, 2017) formulam problema de roteamento de patrulhas policiais, empregando no processo de decisão a estratégia bayesiana e o algoritmo de colônia de formigas. A estratégia adotada é de manter o histórico de visitas das patrulhas nos locais estabelecidos, registrando os níveis de feromônios. Por meio da regra de Bayes, são estabelecidas as probabilidades de cada movimento, dados os ganhos de policiamento calculados para cada ponto e a probabilidade de no movimento ocorrer o encontro de mais de uma patrulha no mesmo ponto. O ganho de policiamento é o inverso da multiplicação do nível de feromônio pela distância ao ponto. As funções de ganho de policiamento e de movimento são reescritas como uma variável aleatória contínua, por meio de uma função de densidade de probabilidade (PORTUGAL; ROCHA, 2013), facilitando a aplicação dos dados. Desta forma, pode-se determinar a visita dos pontos, considerando os com feromônio mais baixo (menos visitados) e mais próximos, com diminuição de risco da concorrência de patrulhas para o mesmo local. A proposta conjuga funcionalidades importantes para o modelo a ser apresentado.

Nesta seção se discutiu as estratégias de decisão para o patrulhamento multiagente voltado policiamento preventivo de *hotspots*. Encerra-se a apresentação de referências teóricas sobre o tema. O próximo passo é a contextualização do problema, quando serão trazidas informações da relevância da discussão para academia e para a sociedade.

### 3 CONTEXTUALIZAÇÃO

Preliminarmente, registra-se que a pesquisa utilizará dados de ocorrências e de emprego operacional da Brigada Militar, órgão responsável pelo policiamento ostensivo no Estado do Rio Grande do Sul (BRIGADA MILITAR, 2022). Neste sentido, é importante apresentar as competências do órgão, conceitos relacionados ao tema policiamento e metodologias de planejamento adotadas pela corporação para melhor compreensão da proposta.

A Brigada Militar foi criada pela Lei Provincial nº 7, de 18 de novembro de 1837, desempenhando, atualmente, as atividades de polícia militar no Estado do Rio Grande do Sul. As polícias militares possuem a missão constitucional de exercer a polícia ostensiva e a preservação da ordem pública, conforme o art. 144, § 5º, da Constituição Federal de 1988 (BRASIL, 2022a). O policiamento ostensivo, fardado, planejado pela autoridade competente, busca assegurar o cumprimento da lei, a manutenção da ordem pública e o exercício dos poderes constituídos (BRASIL, 2022b).

A Brigada Militar possui um conjunto de diretrizes gerais, as quais estabelecem normas gerais de ação, com vistas à padronização de assuntos de relevância para a Corporação. A Diretriz Geral da Brigada Militar Nº 003/BM/EMBM/2001 (BRIGADA MILITAR, 2001) estabelece as variáveis de policiamento ostensivo, adotadas para fins de planejamento da corporação. Dentre os tipos de policiamento previstos na norma – Policiamento Geral, Policiamento de Trânsito, Policiamento Rodoviário, Policiamento Ambiental e Policiamento de Guarda –, prestados pela BM, destaca-se o primeiro, como aquele exercido, com exclusividade, pela Brigada Militar que visa satisfazer as necessidades basilares de segurança, inerentes a qualquer comunidade ou a qualquer cidadão. Os processos são meios de locomoção utilizados, a saber: a pé, motorizado, montado, aéreo, em embarcações e em bicicletas. As modalidades são as formas de execução do policiamento: patrulhamento, permanência, diligência e escolta. Patrulhamento é a atividade móvel de observação, fiscalização, reconhecimento, proteção ou mesmo de emprego força desempenhada pelo policial militar (PM) no posto, enquanto, que a permanência é a atividade predominantemente estática de observação, fiscalização, reconhecimento, proteção, emprego de força ou custódia, desempenhada pelo PM no posto.

Este trabalho centra-se no policiamento ostensivo geral, prestado nas vias urbanas das cidades, voltado à garantia da segurança pública para a sociedade. Este patrulhamento acontece, utilizando-se de vários meios de locomoção, como afirmado acima. Excetua-se, no estudo, o patrulhamento aéreo, com uso de helicópteros e aviões, e patrulhamento com embarcações, em face de sua especificidade e inconstância na sua aplicação. E, considerando que se busca a otimização de rondas policiais, serão estudadas as formas de execução: patrulhamento e permanência.

Na Diretriz Geral da Brigada Militar Nº 027/BM/EMBM/2013 (BRIGADA MILITAR, 2013) pode-se encontrar outros conceitos importantes, complementares para a devida compreensão do funcionamento da corporação, no tocante ao patrulhamento e à permanência policial:

- Área: É a circunscrição territorial atribuída à responsabilidade de uma Unidade – Batalhão ou Regimento;
- Posto: É a circunscrição territorial atribuída à responsabilidade de fração elementar ou constituída, atuando em permanência e/ou patrulhamento;
- Itinerário: É o trajeto que interliga pontos-base no posto, percorrido obrigatoriamente pela fração;
- Local de Risco: É todo local que, por suas características, apresente probabilidade de ocorrência policial militar;
- Ocorrência Policial Militar: É todo ato ou fato, criminal ou não, que exige intervenção policial militar, por intermédio de ações ou operações;
- Ação de Presença: É a manifestação que proporciona à comunidade a sensação de tranquilidade, pela expectativa de atendimento policial militar. Ação de presença real consiste na presença física do policial no local. Ação de presença potencial é a capacidade do policiamento ostensivo, num espaço de tempo mínimo, acorrer ao local onde a ocorrência seja iminente ou já tenha surgido.

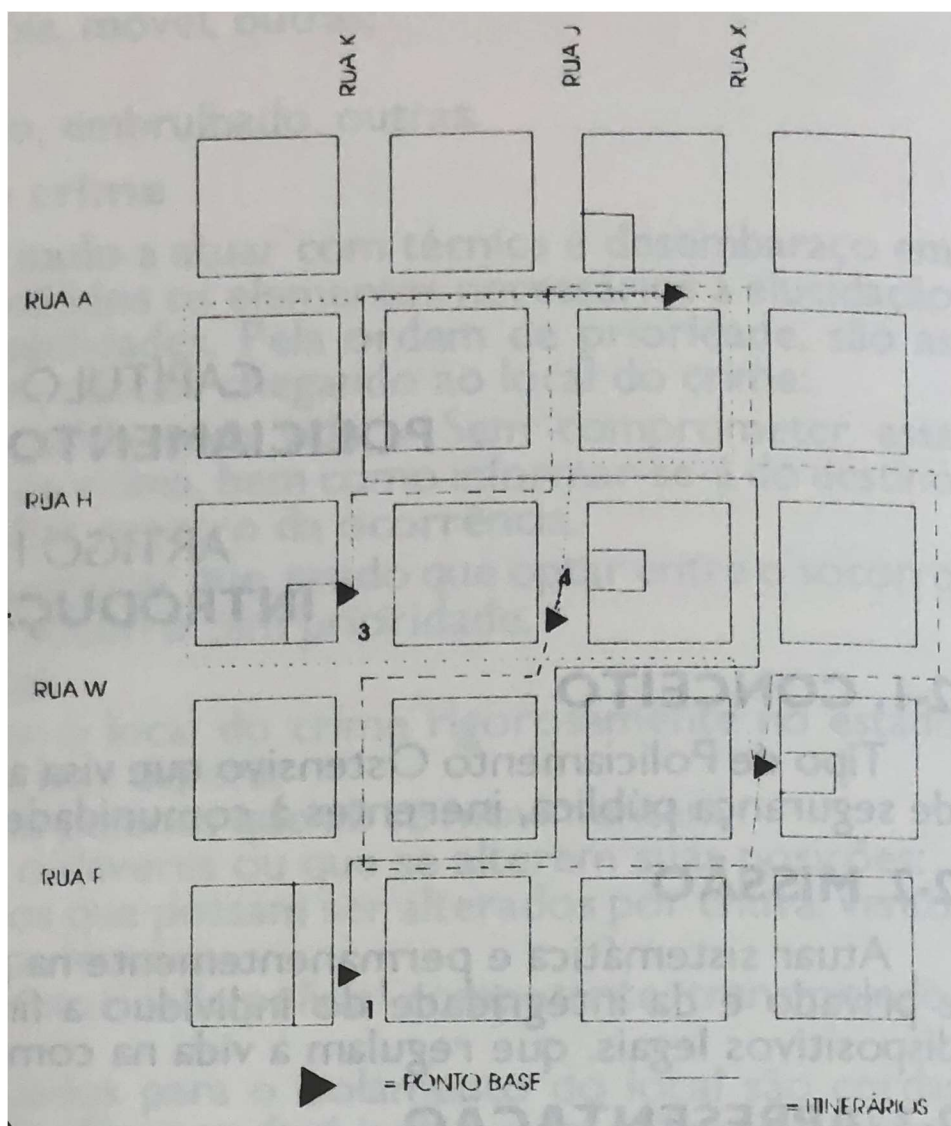
Em face dos conceitos apresentados, pode-se afirmar que o estudo se dará sobre uma área determinada, relacionada a um batalhão de polícia militar. Neste espaço, delimitado geograficamente, existem locais de risco, cujo conceito pode-se relacionar com os *hotspots*, e os postos policiais, dados pelos locais onde é previsto o policiamento, com pontos de parada e itinerários estabelecidos, por meio da ação

de presença, com vistas à prevenção de ocorrências policiais e eventuais atendimentos.

Na diretriz supramencionada, há a previsão de princípios norteadores das ações de policiamento ostensivo. Destaca-se o relativo ao emprego lógico, segundo o qual a disposição de meios, para o exercício da polícia ostensiva e de preservação da ordem pública, deve ser o resultado de julgamento criterioso das necessidades, escalonadas em prioridades de atendimento, da dosagem do efetivo e do material, compreendendo o uso racional do que estiver disponível, bem como de um conceito de operação bem claro e definido, consolidado em esquemas exequíveis. Além disso, quando trata das características do policiamento, ressalta a dinâmica como traço importante, considerando que o desempenho da função de polícia ostensiva e de preservação da ordem far-se-á, com prioridade, no cumprimento e no aperfeiçoamento dos planos de rotina, com o fim de manter continuado e íntimo engajamento da fração com sua circunscrição, para obter o conhecimento detalhado do local de atuação e dos hábitos da população, a fim de melhor servi-la.

Para o planejamento do emprego de patrulhas policiais há diretivas no Manual Básico de Policiamento Ostensivo (INSPETORIA GERAL DAS POLÍCIAS MILITARES, 1993), expedido pela Inspetoria-Geral das Polícia Militares, órgão do Exército Brasileiro. De acordo com o documento, as patrulhas policiais são responsáveis pelo policiamento de um ou mais pontos-bases. Trata-se de espaço físico que exige presença real, contínua ou temporária da polícia, por ser local de risco. Quando houver mais de um ponto-base para a atuação da patrulha policial, esta obedecerá a um cartão-programa.

O cartão-programa é a representação gráfica dos espaços a serem patrulhados. Nele estão indicados os pontos-bases, os itinerários e os horários a serem observados. No documento há uma reprodução da região a ser coberta pela patrulha, por meio de mapa. O cumprimento do cartão-programa não dispensa o policial do atendimento de eventuais ocorrências no seu posto, mesmo fora do itinerário (INSPETORIA GERAL DAS POLÍCIAS MILITARES, 1993).



**Figura 2 - Cartão Programa**

Fonte: Inspetoria Geral das Polícias Militares (1993).

No tocante à gestão de dados estratégicos, a Brigada Militar desenvolve o Programa Avante, tendo por pilares a gestão por resultados, a reestruturação dos processos e a maturidade na gestão de projetos estratégicos, o compartilhamento de boas práticas e a valorização profissional, através do reconhecimento dos efetivos e da ampliação do processo de aprendizado organizacional (BRIGADA MILITAR, 2016). O programa envolve todos os integrantes da corporação, tendo como fim o cumprimento das metas e os resultados necessários ao seu crescimento institucional. Trata-se de trabalho organizado, através do qual acompanha-se ações e indicadores por todas as áreas da Instituição, transformando-se estratégias em resultados.

Para atingir os fins acima, a Brigada Militar possui o sistema IBM Cognos (IBM, 2022) com ferramentas de *business intelligence* capazes de propiciar a criação de painéis e relatórios de dados, integrando bases estaduais disponíveis. Os painéis permitem aos gestores o acompanhamento sobre os principais indicadores e a elaboração de análise sobre o fenômeno da criminalidade, com vistas ao desenvolvimento de ações para o seu enfrentamento. O sistema proporciona o acesso a índices de criminalidade, por ano e mês; a análise de ocorrências, classificando-as por dia da semana e faixa horária, unidades da Brigada Militar, grupos de ocorrências e locais (municípios); a análise geográfica de eventos com mapas temais e de pontos; análise de produtividade, registrando os recursos empregados, as atividades realizadas (comunicações de ocorrência, termos circunstanciados lavrados, prisões em flagrante realizadas, captura de foragidos ou procurados, veículos fiscalizados e pessoas abordadas) e coeficiente de desempenho, dado pela relação entre o efetivo empregado e as atividades realizadas.

Em pesquisa na biblioteca do Instituto de Pesquisa da Brigada Militar com as palavras “roteamento”, “predição” e “hotspot”, nenhum registro foi encontrado. Com a palavra “patrulhamento” foram encontrados 17 registros, mas nenhum deles com o enfoque presente neste trabalho. Não se verifica na Corporação o uso de técnicas e métodos científicos quantitativos voltados a determinar a melhor utilização de recursos limitados e para programação otimizada das operações de uma empresa, conforme proposta presente na Pesquisa Operacional (ANDRADE, 2015).

Destaca-se que a escolha de um batalhão de polícia militar ou regimento de polícia montada para a pesquisa se motiva por se tratar de órgãos da estrutura organizacional com autonomia para a gestão operacional do policiamento em sua circunscrição. A capital tem sua área dividida pelo 1º, 9º, 11º, 19º, 20º e 21º Batalhões de Polícia Militar. Além dessas unidades, atuam na capital o 1º Batalhão de Polícia de Choque e o 4º Regimento de Polícia Montada. O primeiro realiza patrulhas especiais para a prevenção de ocorrências e o policiamento em eventos, enquanto, que o último é empregado também em eventos e no policiamento de parques.

De acordo com dados extraídos do Sistema Integrado de Atendimento de Emergências (SIAE) da Secretaria da Segurança Pública e Avante da Brigada Militar, foram geradas na área central da Capital 428.142 ocorrências, entre chamados do 190 e registros policiais na Brigada Militar e na Polícia Civil, no período de 2015 a

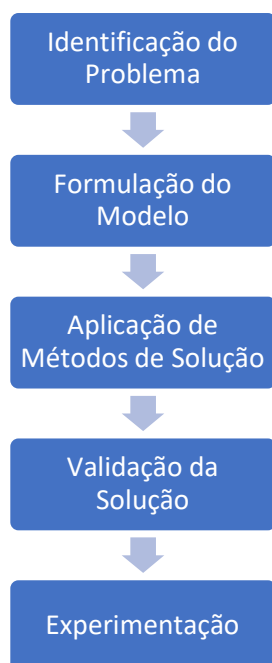
2021. Inobstante os esforços da Brigada Militar se concentrarem em eventos criminais (homicídio, roubo, furto, lesão corporal, ameaça etc.), a corporação é chamada para o atendimento eventos dos mais diversos, tais como, salvamentos de pessoas e animais, incêndios (em apoio aos bombeiros), acidentes de trânsito com danos materiais, averiguações em locais suspeitos, casos de depressão e tentativa de suicídio, disparos de arma de fogo, desaparecimentos de pessoas, mulheres em trabalho de parto etc.

Sendo assim, busca-se, neste projeto, o desenvolvimento de um modelo matemático para o planejamento otimizado de rotas policiais, para o atendimento de unidade de policiamento de Porto Alegre. No capítulo seguinte será detalhada a metodologia utilizada para o atingimento dos objetivos do trabalho.

## 4 METODOLOGIA

A Pesquisa Operacional, como área do conhecimento, se caracteriza pelo uso de técnicas e métodos científicos qualitativos por equipes interdisciplinares, no esforço de determinar a melhor utilização de recursos limitados e para programação otimizada de operações de uma empresa (ANDRADE, 2015). Dentre seus objetivos pode-se identificar a conversão de dados em informações significativas, o apoio ao processo de tomada de decisão de formas transferíveis e independentes e a criação de sistemas computacionais úteis para os usuários não técnicos (LACHTERMACHER, 2018).

Em face das considerações apresentadas sobre o problema de roteamento de patrulhas policiais, pretende-se buscar solução usando-se a metodologia de resolução da Pesquisa Operacional, com vistas à identificação de rotas de patrulha dinâmicas. Desta forma, o processo de resolução pode ser sistematizado, conforme figura abaixo, cujos passos serão tratados nas seções seguintes:



**Figura 3 - Processo de resolução de um problema**

Fonte: Elaboração própria.



#### 4.1 IDENTIFICAÇÃO DO PROBLEMA

Preliminarmente, registra-se que problema pode ser conceituado como sendo a divergência existente entre o resultado planejado e esperado e um resultado não previsto e indesejado obtido em determinada situação (LONGARAY, 2013). Em face desse conceito, a fase formulação do problema envolve a definição clara dos objetivos a serem alcançados e os possíveis caminhos para a solução do modelo, assim como, limitações técnicas do sistema e relações desse com outros sistemas da empresa ou do ambiente externo (BELFIORE; FÁVERO, 2012).

Neste estudo, busca-se a otimização do roteamento de patrulhas policiais. Parte-se da concepção que patrulhas aleatórias, por vezes determinadas meramente pela experiência policial, não trazem os melhores resultados (CHEN; CHENG; WISE, 2017; RUMI; QIN; SALIM, 2020; RUMI; SHAO; SALIM, 2020). Inobstante a isso, estudos comprovam a importância do patrulhamento como forma efetiva de prevenção (CHEN; CHENG; WISE, 2017; LI et al., 2011; REIS et al., 2006b; RUAN et al., 2005; RUMI; SHAO; SALIM, 2020). Desta forma, deve-se buscar métodos racionais para dar maior eficiência na distribuição dos recursos policiais (LI et al., 2011; TAYEBI et al., 2014), como resposta ao clamor da população por mais segurança.

A definição de *hotspots*, locais com maior concentração dos crimes no tempo e espaço (BRANTINGHAM; BRANTINGHAM, 1995; CHAINEY; TOMPSON; UHLIG, 2008; ECK; WEISBURD, 2015) para a priorização dos locais das ações policiais é uma das estratégias escolhida. Neste sentido, os dados dos eventos criminais serão avaliados sob aspectos do tempo e de lugar.

Preliminarmente, se buscará identificar sazonalidades relacionadas à hora do dia, período diurno ou noturno, dia do mês, dia da semana, mês do ano, estação e ano, a fim de possibilitar a predição de comportamento do crime, em face de variáveis temporais. E num segundo momento, se identificará estruturas notáveis instaladas na área em estudo que possam interferir na ocorrência de crimes.

De posse dos dados acima apresentados, serão ponderados os eventos criminais e estruturas notáveis de modo a mensurar o grau de risco para novas ocorrências no espaço limitado para o *hotspot*. Algoritmo de predição será avaliado

para determinar os *hostpots* com maior chance de recorrência de crimes, cuja classificação será usada para solução do problema de roteamento.

Outro ponto importante a ser tratado é a forma de funcionamento das patrulhas policiais. A velocidade da patrulha varia conforme o tipo de processo (a pé, motorizada, de bicicleta), e a criticidade do deslocamento, seja em patrulhamento ou em deslocamento para ocorrência, quando deve ser no menor tempo possível. As patrulhas possuem momentos de troca de turno e jornadas distintas. Sendo assim o modelo deve permitir a coordenação dos recursos empregados.

Considerando tais peculiaridades, será utilizado o método de Chen, Cheng e Wise (2015, 2017), o qual emprega no processo de decisão a estratégia bayesiana e o algoritmo de colônia de formigas. Por meio dele é possível o registro histórico das visitas aos *hotspots* e, por consequência determinar a ociosidade. Também possui mecanismo para evitar a sobreposição de recursos, mesmo na falha de um comando centralizado. Ressalta-se que o método sofreu modificações por este autor, a fim de permitir a mitigação de efeitos da proximidade de *hotspots* na escolha da próxima visita, assim como, foi introduzido pesos para os *hotspots*, conforme o grau de importância, usando método de predição, como será demonstrado.

A mensuração dos resultados se dará por três vieses: 1) a ociosidade dos chamados *hotspots*, ou seja, sobre o tempo entre visitas das patrulhas policiais, a qual deve ser minimizada; 2) o tempo de resposta das patrulhas para o atendimento dos eventos policiais em dado período; e 3) a taxa de acertos (índice de precisão da previsão) na determinação dos locais de parada em relação as ocorrências policiais registradas nos *hotspots*, em dado período. Considera-se *hotspots* locais determinados geograficamente, sensíveis para a ocorrência de eventos criminais, cuja incidência está relacionada com estruturas notáveis presentes, histórico no espaço e tempo.

Em face do exposto acima, o problema proposto é estabelecer um sistema de otimização de roteamento de patrulhas policiais para minimização da ociosidade nos *hotspots* e do tempo de resposta no atendimento de ocorrências, inspirado em estratégia multiagente, sabendo-se que as patrulhas operam em jornadas de serviço determinadas e movimentos controlados por central de operações, a fim de realizar o atendimento de ocorrências e ações preventivas de patrulhamento e permanência,

em pontos de maior densidade de ocorrências e estruturas notáveis, considerando-se a análise preditiva sobre dados históricos por horário e dia da semana.

#### 4.2 FORMULAÇÃO DO MODELO

De acordo com Virgillito (2017), a modelagem é a maneira científica de se construir cenários ou mecanismo que ajudem a atingir resultados ou objetivos desejados. O processo de modelagem permite a construção de um esquema que representa o problema. Envolve o engendramento de todos os fatores, circunstâncias e possibilidade, de acordo com os nossos objetivos e interesses (LONGARAY, 2013).

O problema será formulado como um modelo de simulação discreta, no qual o comportamento dos agentes será dinamicamente avaliado, considerando questões temporais do histórico de ventos criminais e características locais, relacionadas às estruturas notáveis.

O movimento das patrulhas policiais ocorre de forma coordenada. O processo decisório para escolha dos próximos pontos de patrulhamento considera a posição das demais patrulhas, a ociosidade dos *hotspots*, a distância entre os pontos a serem patrulhados, a análise preditiva do crime da região estudada e o despacho para o atendimento de chamadas.

Há quatro eventos possíveis: 1) estar no depósito; 2) estar em trânsito entre *hotspots*; 3) estar para em um *hotspot*; e 4) estar no atendimento de uma ocorrência. A avaliação sobre as possibilidades de mudança do *status* de cada patrulha ocorre a cada minuto. O desenvolvimento do modelo é detalhado no capítulo 5.

#### 4.3 VALIDAÇÃO DA SOLUÇÃO

A validade de um modelo está relacionada a sua capacidade de representar ou prever, com precisão aceitável, o comportamento do sistema em estudo (BELFIORE; FÁVERO, 2012). A sua legitimação passa pelo reconhecimento por parte do decisor se o modelo atende às necessidades solicitadas (LONGARAY, 2013).

No caso em estudo, o modelo não será aplicado diretamente sobre o mundo dos fatos. Por meio de simulação, serão realizadas experimentações com vistas a

identificar se o modelo permite uma aceitável representação da realidade, em face do domínio do problema apresentado (BORENSTEIN, 1998). Registra-se que em face da complexidade do modelo, certas restrições podem ter sido negligenciadas.

Salienta-se, neste sentido, considerando que se trabalha nesta pesquisa com dados de segurança pública, informações precisas de emprego de recursos humanos e operacionais, quanto aos locais e forma de aplicação, não serão aqui conhecidas. Tal exposição pode levar a riscos ao funcionamento de serviço essencial. Contudo, estão à disposição da pesquisa o quantitativo de patrulhas, nos processos a pé, de bicicleta e motorizado (carros e motocicletas), horários de início e duração das jornadas. Inobstante a possibilidade de aplicação do método no patrulhamento a cavalo, não foram obtidos dados de emprego neste processo.

Serão usados cenários de emprego operacional verossímeis na área determinada pela pesquisa, considerando a experiência do autor e os dados disponíveis. Por outro lado, ressalta-se que os dados de ocorrências policiais refletem a realidade dos registros realizados nos sistemas públicos e as estruturas notáveis são oriundas de informações disponibilizadas pelos usuários dos serviços do Open Street Maps e da Secretaria da Segurança Pública, o que possibilita maior realidade à simulação.

A avaliação de custos, considerando a função objetivo apresentada, comparará os resultados perante os cenários de emprego operacional apresentados, considerando os eventos criminais ocorridos no período de 1º a 10 de dezembro de 2021. Isto permitirá, o cálculo da ociosidade média, o índice de precisão da previsão e o tempo médio para atendimento das chamadas de urgência. Eventuais discrepâncias estaticamente importantes nos resultados serão consideradas para correção do modelo.

De qualquer forma, adverte-se que o modelo requer aprimoramentos e revisões, possíveis em testagem de campo, com uso de dados reais de emprego. A matriz de custos de deslocamentos entre os vértices (*hotspots*) deve ser aprimorada para permitir a requisição de tais valores em tempo real, assim como, a localização dos vértices refletir o planejamento do órgão policial responsável pela área do estudo. Os custos, relativos ao afastamento de patrulhas para o atendimento de ocorrências, durante a sua jornada de serviços, em trabalhos futuros precisam ser tratados.

Questões da rotina operacional, como tempo dedicado para alimentação, realização de necessidades fisiológicas, abastecimento de veículos, dentre outras, precisam de avaliação.

## 5. DESENVOLVIMENTO DO MODELO

Este capítulo é voltado ao desenvolvimento do modelo e a apresentação dos métodos de solução, considerando o descrito no capítulo antecedente.

### 5.1 MODELO PROPOSTO

Para o problema em questão, o processo de modelagem inicia-se com a identificação dos *hotspots*. Neste sentido, registra-se que os eventos atendidos pela polícia ( $O_{Tot}$ ) envolvem ocorrências criminais ( $O_{Crim}$ ) e não criminais ( $O_{NCrim}$ ). O estudo se concentrará em eventos relativos a delitos (homicídio, lesão corporal, estupro, furto, roubo etc.), ou seja, ações humanas tipificadas na legislação penal como crimes, considerados sensíveis a ações de policiamento ostensivo ( $O_{Crim}$ ).

**Quadro 1 - Notações**

Notação	Descrição
$O_{Tot} = O_{Crim} + O_{NCrim}$	Conjunto O é composto por ocorrências criminais e não criminais.
$O_{Tot} = \{o_1, o_2, \dots, o_n\}$	Conjunto de ocorrências policiais (criminais e não criminais).
$Grids = \{g_{1t}, g_{1b}, g_{1l}, g_{1r}, g_{2t}, g_{2b}, g_{2l}, g_{2r}, \dots, g_{nt}, g_{nb}, g_{nl}, g_{nr}\}$	Conjunto de <i>Grids</i> possui as medidas de coordenadas superior, inferior, esquerda e direita.
$H = \{h_1, h_2, \dots, h_n\}$	Conjunto dos <i>Grids</i> com maior densidade de ocorrências ( <i>hotspots</i> ).
$E = \{ep_1, ep_2, \dots, ep_n\}$	Conjunto de eventos previstos nos <i>hotspots</i> .
$s = [13, 15]$	Período de parada de uma patrulha num <i>hotspot</i> . Koper (1995) sugere parada entre 13 e 15 minutos.
$d$	Período de tempo em que uma patrulha fica empenhada no atendimento de ocorrência.
$W = \{w_1, w_2, \dots, w_n\}$	Peso dos <i>hotspots</i>
$V = \{v_1, v_2, \dots, v_n\}$ –	Vértices relacionados aos <i>hotspots</i>
$c_{ij}$	Custo em distância entre os vértices $i$ e $j$ .
$T = \{6, 8, 12\}$	Tempo limite de patrulhamento (jornada)
$R = \{r_1, r_2, \dots, r_n\}$	Equipe de patrulheiros
$P = \{a \text{ pé, motorizado (carro), motorizado (motocicleta), de bicicleta}\}$	Tipos de processos de patrulhamento
$SP = \{sp_{a \text{ pé}}, sp_{carro}, sp_{motocicleta}, sp_{bicicleta}\}$	Velocidade de patrulhamento
$M = V \times V, c_{ij}$	Matriz de custos, dados pelas distâncias entre os vértices $v$ .

Fonte: elaboração própria.

A área do estudo será dividida em *grids* (MALIK et al., 2014; PERRY et al., 2013). A bibliografia apresenta variações sobre formato e as dimensões a serem utilizadas. Adotou-se o formato de hexágono de 350 metros de lado e aproximadamente 318.264 m<sup>2</sup> de área. Para precisar a localização de cada hexágono, as longitudes e latitudes superior, inferior, esquerda e direita são armazenadas (coordenadas geográficas). Evita-se dimensões superiores, as quais possam implicar na falácia da unidade de área (BLOCK, 1993), quando informações de vizinhanças heterogêneas são identificadas como únicas. Ademais, do centro do hexágono, com a medida escolhida, o policial pode ter visão de boa parte do perímetro, assim como, agir com rapidez no atendimento de ocorrência na área.

Nos *grids* são introduzidos os locais dos eventos policiais ocorridos, no período do estudo, assim como, as estruturas notáveis, precisamente por meio de suas coordenadas geográficas. Tais dados são contabilizados, conforme o tipo, com vistas à classificação. Partindo-se do pressuposto que mais da metade dos crimes estão concentrados em espaços determinados (BRAGA, 2005; ECK; WEISBURD, 2015), usa-se o princípio de Pareto (GONZALEZ, 2022; SCHIFFER, 2019; STEINMAN et al., 2021) para identificar os *grids*, onde se encontram até 80% das ocorrências policiais, como *hotspots*. Após a contagem de ocorrências, descartam-se os *grids* com o restante das ocorrências.

Demonstrados os procedimentos para determinação dos *hotspots* e *grids*, parte-se para análise preditiva, com vistas à identificação dos possíveis alvos da criminalidade. Considera-se o quantitativo dos eventos criminais até 350 de um ponto qualquer como variável independente, e dependentes o *grid*, a latitude, a longitude, o ano, o mês, o dia da semana, o dia do mês, a estação, dia ou noite e a hora do acontecimento do fato (série temporal), e a presença de estruturas notáveis, a saber bares/restaurantes, pontos de transporte público, lojas, escolas/colégios/universidades, hospitais/postos de saúde/clínicas, parques/praças e câmeras de videomonitoramento num raio de 150 metros do ponto estudado. Em relação às estruturas notáveis, elas somente contam nos dias da semana e horários de funcionamento.

Preliminarmente, os dados serão limpos, removendo valores discrepantes e tratando-se os dados ausentes. Parte-se para a identificação dos modelos analítico

preditivos adequados ao problema, com ênfase em previsões, a partir da base histórica de dados e séries temporais. Em seguida, os dados são pré-processados em um formato adequado para o algoritmo de modelagem escolhido. É especificado um subconjunto dos dados a serem usados para treinar o modelo e para validação do modelo em teste, correspondentes a 80% e 20%, respectivamente, do quantitativo de dados.

Neste sentido, serão realizados experimentos com método de árvore de decisão (ALMANIE; MIRZA; LOR, 2015; YU et al., 2011), a fim de permitir a análise das ferramentas que trazem melhor resultados para o problema em questão. A predição da quantidade de acontecimento de crimes em dado  $h_i$  em dado dia e hora será utilizada para o cálculo dos movimentos das patrulhas.

Desta forma, a partir da previsão de eventos para um dado dia e horário, em cada *hotspot*, é calculada a densidade de ocorrências que se estima possam acontecer nas áreas determinadas, conforme fórmula abaixo:

$$d_j = \frac{ep_j}{\sum_{i=1}^n ep_i} \quad (2)$$

As densidades normalizadas de crimes previsto nos  $n$  *hotspots* é normalizada:

$$dNORMAL_j = \frac{ep_j - ep_{min}}{ep_{max} - ep_{min}} \quad (3)$$

A densidade de eventos previstos para cada *hotspot*  $i$  será utilizada como peso  $w_i$  para determinação das prioridades na solução do problema patrulhamento da área determinada.

Cada *hotspot* possui um local de referência  $v$  para parada das patrulhas policiais pelo período  $s$  (13 a 15 minutos). Os vértices  $v$  possuem coordenadas geográficas determinadas. Além dos vértices para a parada das patrulhas, deve ser estabelecido o ponto de saída e de retorno das patrulhas (depósito).



Em relação aos  $n$  vértices, incluído o ponto de partida das patrulhas, serão apuradas as menores distâncias, a fim de formar uma matriz  $V \times V$  com custos  $c_{ij}$  entre os vértices. Associa-se a cada meio de patrulhamento (a pé, de carro, de motocicleta, de bicicleta) uma velocidade de referência  $sp$  para apuração do tempo de deslocamento entre os vértices. O tempo de deslocamento entre vértices é dado pela expressão abaixo:

$$\Delta t = \frac{c_{ij}}{sp_k} \quad (4)$$

onde  $c_{ij}$  é a distância em quilômetros entre os vértices  $i$  e  $j$  e  $sp_k$  a velocidade no processo de patrulhamento  $k$ .

No modelo serão utilizadas as equações estabelecidas por Chen, Cheng e Wise (2015, 2017) para o controle de nível de feromônio e de probabilidade de movimento, dado o ganho de policiamento e o movimento, considerando a posição das demais patrulhas, quanto aos *hotspots*.

Quanto ao nível de feromônio de cada *hotspot*, este sofre alteração, conforme visitas são realizadas (depósito de feromônio), operando-se da seguinte forma:

$$Ph_{h_i}(t) = Ph_{h_i}(t - 1) + Ph_d \quad (5)$$

E o tempo decorrido desde a última visita (decaimento) é calculado conforme a função abaixo:

$$Ph_{h_i}(t) = Ph_{h_i}(t_0) \times \lambda_{h_i}^{t-t_0} \quad (6)$$

onde  $Ph_d$  é o feromônio depositado e  $\lambda_{h_i} \in (0,1)$  é a taxa de decaimento do feromônio no *hotspots*  $h_i$ .

Contudo, o registro de feromônio proposto não entrega mecanismo de decisão, considerando níveis iguais em *hotspots*, a serem patrulhados. Neste sentido, Chen, Cheng e Wise (2015) introduzem o modelo de decisão bayesiana, como forma de estabelecer qual *hotspot* dos  $n - 1$  deve se deslocar uma patrulha após o atendimento do ponto atual. Apresenta a seguinte fórmula, aplicando a regra de Bayes:

$$P(\text{move}(h_i)|G_{h_i}, S_{h_i}) = P(\text{move}(h_i)) \times [P(G_{h_i}|\text{move}(h_i)) | P(G_{h_i})] \times [P(S_{h_i}|\text{move}(h_i)) | P(S_{h_i})] \quad (7)$$

onde  $P(\text{move}(h_i))$  representa o conhecimento prévio do problema, como a priorização de certos *hotspots* especiais, exigindo uma frequência de visitas mais alta do que outros. Aqui, pode se introduzir alguma forma de ponderação do *hotspot*, a fim de diferenciar níveis de risco para ocorrência de crimes.

O ganho de patrulhamento  $G_{h_i}$  no hotspot  $h_i$ , no tempo  $t$ , é dado por:

$$G_{h_i}(t) = \frac{1}{[Ph_{h_i}(t) \times NORMdmin(p, h_i)]} \quad (8)$$

onde  $Ph_{h_i}(t)$  é o nível de feromônio e  $NORMdmin(p, h_i)$  a distância normalizada entre um ponto  $p$  e o *hotspots*  $h_i$ . A função ganho ( $G_{h_i}$ ) pode ser reescrita como uma variável aleatória contínua, por meio de uma função de densidade probabilidade  $f(g)$  (Portugal e Rocha, 2013):

$$f(g) = 1/M \times \ln\left(\frac{1}{L}\right) \times \exp\left(\ln\left(\frac{1}{L}\right) \times g/M\right) \quad (9)$$

onde  $L, M > 0$  são constantes de controle de distribuição da função, no qual  $L$  controla a probabilidade dos valores zero ganharem, e  $M$  é o ganho de saturação.

As equações  $P(S_{h_i}|\text{move}(h_i))$  e  $P(S_{h_i})$  são usadas para a coordenação dos patrulheiros. A ideia básica é que um patrulheiro deve evitar patrulhar o mesmo *hotspot* que seus companheiros de equipe. Utilizando a estratégia bayesiana, a distribuição de  $P(S_{h_i} = s)$  é dada por (PORTUGAL; ROCHA, 2013):

$$P(S_{h_i} = s) = 2^{R-(s+1)} / (2^R - 1) \quad (10)$$

onde  $R$  é o número de patrulheiros.

A probabilidade de movimento é dada por:

$$P(\text{move}(h_i)|G_{h_i}, S_{h_i}) = c \times \exp\left(\ln\left(\frac{1}{L}\right) \times \frac{g}{M} / 2^{S_{h_i}}\right) \quad (11)$$

onde  $c$  é uma constante através de todos  $h_i$ .

Neste sentido, o próximo *hotspot* para patrulhar é aquele com maior probabilidade:

$$h_{next} = \arg \max P(move(h_i)|G_{h_i}, S_{h_i}) \quad (12)$$

Na equação (8), relativa ao ganho de patrulhamento  $G_{h_i}$  no *hotspot*  $h_i$ , no tempo  $t$ , propõe-se as seguintes alterações:

$$G_{h_i}(t) = \frac{(1+w_{h_i})^\theta}{[\alpha \times (Ph_{h_i}(t)) + \beta \times (Ph_{h_i} \times NORMdmin(p, h_i))]} \quad (13)$$

Onde,  $w_{h_i}$  é a significância do *hotspot*,  $Ph_{h_i}(t)$  o nível de feromônio e  $NORMdmin(p, h_i)$  a distância normalizada entre um ponto  $p$  e o *hotspot*  $h_i$ . As constantes  $\alpha$  e  $\beta$ , onde  $\alpha + \beta = 1$ , estabelecem o quanto o mecanismo de decisão deve relevar, em relação à distância e o índice de feromônio para os próximos *hotspots*, visando evitar que a patrulha fique adstrita a apenas uma das estratégias. Os valores são ponderados com a constante  $\theta$ . A equação apresenta por Chen, Cheng e Wise (2015) não prevê a ponderação de *hotspots*, do feromônio e da distância, o que pode gerar distorções, enfatizando-se pontos mais próximos e o centro da média da ociosidade geral, em prejuízo dos *hotspots*.

Quanto à probabilidade de movimento para um *hotspot*  $h_i$ , aplica-se a equação (9), na forma de uma variável aleatória contínua, por meio de uma função de densidade probabilidade  $f(g)$ . Mantém-se o modelo proposto por Chen, Cheng e Wise (2015, 2017) e Portugal e Rocha (2013), adequando-se as constantes  $L$  e  $M$  presentes na equação.

Quanto à coordenação dos patrulheiros, utiliza-se a equação (10) para determinar a distribuição da probabilidade dos *hotspots* a serem policiados, evitando-se a sobreposição de recursos. Por meio da equação (11), calcula-se o movimento de cada patrulheiro, considerando-se o ganho de policiamento e a coordenação dos patrulheiros no terreno.

De acordo com a equação (12), o próximo *hotspot*  $h_i$  a ser visitado pela patrulha  $r$  é dado pela máxima probabilidade do movimento para  $h_i$ , dado o ganho de policiamento, calculado pela equação (8), e a coordenação dos patrulheiros, conforme equação (10). Contudo, diferentemente do proposto por Chen, Cheng e Wise (2015,

2017), são estabelecidas probabilidades para todos os hotspots em  $H$ , com base nos pesos estabelecidos na equação (13).

Conforme, já afirmado na Seção 2.2, a ociosidade instantânea de um *hotspot*  $h_i \in H$  no tempo  $t$  é dada por  $I_{h_i} = t - t_{l(h_i)}$ , onde  $t_{l(h_i)}$  refere-se ao último  $h_i$  visitado por um patrulheiro. A média de ociosidade do *hotspot*  $h_i$  no tempo  $t$  é definido como  $\overline{I_{h_i}}(t) = (t - t_0)/(C_{h_i} + 1)$ , onde  $t_0$  é o tempo de início e  $C_{h_i}$  trata-se do número de visitas ao *hotspot*  $h_i$ .

Chen, Cheng e Wise (2015, 2017) estabeleceram como função objetivo a minimização da média de ociosidade de todos os *hotspots*, escrita da seguinte forma:

$$\min \frac{1}{n \times \sum_{i=1}^n \overline{I_{h_i}}(t)} \quad (15)$$

Cabe destacar que diferentemente de Chen, Cheng e Wise (2015, 2017), a presente pesquisa considera para a decisão do movimento a previsibilidade de ocorrências nos *hotspots*, assim como, o atendimento das ocorrências policiais que possam acontecer no decorrer do período, prejudicando a alocação de patrulhas para o atendimento de *hotspots*.

Na equação abaixo, verifica-se como o tempo de resposta para uma ocorrência  $o_j$  pode ser apurado como o mínimo da divisão do custo (distância) entre o vértice  $i$  (vértice onde se encontra a patrulha) e o vértice  $j$ , relativo ao *hotspot*, onde se deu a ocorrência a ser atendida, pela velocidade das patrulhas  $r$  disponíveis, conforme o tipo de deslocamento  $k$  (a pé, carro, motocicleta ou bicicleta):

$$tempo\_resposta_{o_j} = \min \left( \frac{c_{ij}}{sp_{rk}} \right) \quad (16)$$

O tempo de resposta médio pode ser minimizado utilizando o seguinte modelo de programação matemática:

$$\min \frac{\sum_{i=1}^n tempo\_resposta_{o_i}}{n} \quad (17)$$

dado que:

$$h_1, h_2, \dots, h_n \in H$$

$$v_1, v_2, \dots, v_n \in V$$

$$c_{ij} \in V \times V = M$$

$$o_1, o_2, \dots, o_n \in O_{Tot}$$

$$1 \leq r \leq R, R \in \mathbb{N}$$

$$sp_{ape}, sp_{carro}, sp_{motocicleta}, sp_{bicicleta} \in SP$$

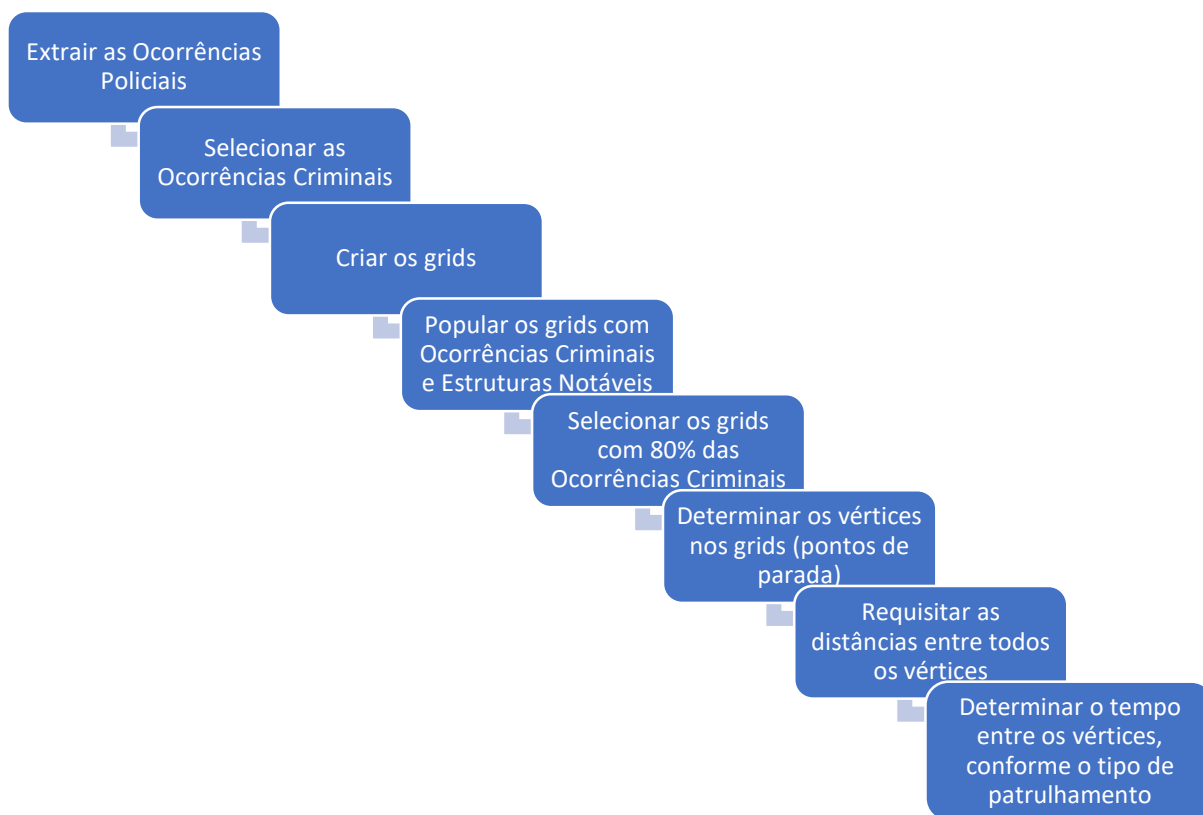
Ou seja, busca-se a minimização do tempo médio de atendimento das ocorrências  $O_{Tot}$ , considerando os custos apurados na matriz  $M$  para o conjunto de vértices  $V$  relacionado aos *hotspots*  $H$ , levando em consideração as patrulhas  $R$  disponíveis no momento da sua alocação e suas velocidades, com vistas à estimativa do menor tempo para chegada nas ocorrências.

## 5.2 SELEÇÃO DE HOTSPOTS

Superadas as fases de identificação do problema e estabelecimento do modelo matemático, parte-se para aplicação dos métodos necessários para sua solução. É nesta fase que são desenvolvidos algoritmos e procedidos os cálculos, a fim de determinar a solução ótima para o modelo (LONGARAY, 2013).

Os processos relacionados ao tratamento de mapas, no tocante a carga de dados de ocorrências policiais ( $O_{Tot}$ ) e estruturas notáveis em ambiente georreferenciado, subdivisão do espaço estudo em hexágonos justapostos (*Grids*) e contagens de objetos se deram na plataforma QGIS (QGIS DEVELOPMENT TEAM, 2021). Os dados foram exportados no formato Microsoft Excel (2019) para permitir sua manipulação em ambiente Python (VAN ROSSUM; DRAKE JR, 1995).

A figura abaixo detalha os procedimentos realizados:



**Figura 4 - Fluxograma da preparação dos dados**

Fonte: elaboração própria.

Por meio da biblioteca Pandas (MCKINNEY, 2010), os dados foram carregados. Os eventos criminais ( $O_{Crim}$ ) são separados, excluindo-se os não criminais ( $O_{NCrim}$ ). Do total de *grids* hexagonais, seleciona-se apenas os correspondentes a 80% do total de ocorrências criminais, denominados *hotspots*.

A escolha dos  $n$  vértices leva em consideração a experiência policial, com vistas a garantir a maior visibilidade da presença da patrulha naquele local (cruzamentos e vias mais movimentadas). Além disso, elege-se o vértice de depósito de onde partirão as patrulhas policiais. São dados repassados pelo usuário ao sistema.

As distâncias entre os  $n$  vértices, incluído o ponto de partida das patrulhas, são obtidas por meio API Bing Maps (MICROSOFT CORPORATION, 2022), formando a matriz  $V \times V$  com custos  $c_{ij}$ . A fim de facilitar a execução do modelo, os custos foram requisitados na plataforma Bing de uma única vez, considerando todas as possibilidades de deslocamento. É possível realizar requisições em tempo real, relevando as condições de tráfego no momento. Além disso, se obtém de forma automática o tempo, no caso do transporte com veículo automotor. Para se obter o custo tempo para as demais formas de patrulhas, considerando-se as velocidades diferentes da a pé, a cavalo, de bicicleta e de motocicleta, divide-se o custo  $c_{ij}$  pela velocidade  $sp_k$ , conforme velocidades constantes no quadro abaixo:

**Quadro 2 - Processos de Policiamento**

Tipo	Jornada (em geral)	Horário	Intervalo (refeição)	Velocidade
A pé	6 ou 8 horas	Conforme o planejamento, mas há turnos padronizados: 1º turno (00h30 – 06h30); 2º turno (06h30 – 12h30); 3º turno (12h30 – 18h30); 4º turno (18h30 – 00h30).	Jornada de 12 horas (30 minutos)	5,1 km/h (Mohler et al, 2005)
Motorizada (carro)	6, 8 ou 12 horas			30 km/h (depende do limite da via)
A cavalo	6 horas			7 km/h (referência)
Bicicleta	6, 8 ou 12 horas			15 km/h (referência)
Motocicleta	6, 8 ou 12 horas			45 km/h (depende do limite da via)

Fonte: elaboração própria.

Para a análise preditiva de ocorrências é usada a XGBoost (CHEN; GUESTRIN, 2016), biblioteca de reforço de gradiente escalável, portátil e distribuída. Como parâmetros foram adotados: impulsor de árvore de decisão *gbtree*, taxa de aprendizado de 0,1, profundidade máxima de 5 e 140 estimadores.

Como resultado se obtém a previsão de episódios ( $ep_j$ ) por vértice (*hotspot*) no dia e horário em referência, num raio de 350 metros. A partir da divisão de  $ep_j$  pelo  $\sum_{i=1}^n ep_i$  se tem a densidade ( $d_j$ ) de crimes no *hotspot*  $j$ . O valor normalizado ( $dNORMAL_j$ ) será utilizado como peso ( $w_j$ ).

Para cada patrulha  $r$  devem ser informados o tipo (a pé, de bicicleta, de motocicleta ou viatura), o início do trabalho e a jornada ( $T$ ), em minutos. Adota-se o valor de 15 minutos ( $s$ ) para o período de permanência das patrulhas nos *hotspots*.

## 5.4 DINÂMICA DO MODELO

O relógio de simulação avança em intervalos fixos de tempo (minuto a minuto), usando-se o algoritmo descrito na figura 5. Parte-se do tempo 0 até 1439 ( $\Delta t$ ) para um dia de serviço, ou mais. Adverte-se que as escalas policiais não terminam necessariamente à meia-noite do dia, mas podem invadir o dia subsequente. O algoritmo é executado a cada intervalo de tempo.

---

### Algoritmo 1 – Busca solução

---

```

1: caminhos ← lista[R,H]
2: enquanto t ≤ Δt
3:   enquanto r ≤ tamanho(R)
4:     se patrulha_livre(t,r) == verdadeiro
5:       se chamada_ocorrencia(t) == verdadeiro
6:         patrulha_livre(t+d,r) == false
7:         caminhos[r].adiciona(h,d,'OCORRÊNCIA')
8:       senão
9:         enquanto h ≤ tamanho(H)
10:          ultimo_hotspot = caminhos[r][-1]
11:          ganho(ultimo_hotspot,h,W)
12:          colaboracao(r,R)
13:          proximo_hotspot=max(move(ganho,colaboracao))
14:          h = h + 1
15:          caminhos[r].adiciona(próximo_hotspot,s,'PATRULHAMENTO')
16:          incrementa_feromonio(próximo_hotspot, α)
17:          decaimento_feromonio(H, β)
18:          r = r + 1
19:          t = t + 1

```

---

**Figura 5 - Algoritmo de busca da solução**

Fonte: elaboração própria.

Começa com a lista bidimensional *caminhos* sendo inicializada. Ela guardará todos os *hotspots* a serem percorridos pela patrulha *r* em patrulhamento, assim como, em decorrência de chamadas de emergência. No laço da linha 2, será controlado o tempo de funcionamento  $\Delta t$  da simulação. O tempo é contabilizado a cada minuto. Em seguida, na linha 3, tem-se o laço relativo às patrulhas *r*. A patrulha *r* estará livre (verdadeiro) no tempo *t*, se estiver no período de sua jornada de trabalho e não



empenhada em ocorrência. Estando nesta condição, a patrulha poderá ser empenhada no atendimento de ocorrência (linhas 5 e 6), ou calcula-se, em relação ao último *hotspot* visitado pela patrulha  $r$  o eventual ganho de policiamento (linha 11, Equação 9) e a probabilidade de outros patrulheiros estarem buscando o mesmo destino (linhas 12, Equação 10). O próximo *hotspot* será escolhido, considerando o valor máximo da probabilidade do movimento (valor estimado por meio de função densidade de probabilidade de natureza determinística), considerando o ganho de patrulhamento (Equação 11) e a colaboração entre os patrulheiros (linha 12). Na linha 15, o *hotspot* escolhido é inserido na lista *caminhos*, tendo o seu grau feromônio aumentado (Equação 5). Ao final, todos os *hotspots* sofrem decaimento de feromônio (linha 17) no lapso temporal  $t$ , relativo a um minuto transcorrido (Equação 6).

Para exemplificar o funcionamento, no quadro abaixo, apresenta-se resultados para um cenário hipotético. No tempo 0, todas as  $k$  patrulhas encontram-se no vértice de partida. Neste momento, todas as patrulhas estão livres para patrulhamento. Calcula-se então o ganho de policiamento para cada patrulha, conforme demonstrado acima. As patrulhas partem para os vértices escolhidos. Conforme a distância e velocidade da patrulha (a pé, a cavalo, de bicicleta, de motocicleta ou carro), são determinados os tempos em trânsito das patrulhas. Chegando no vértice escolhido, a patrulha ficará parada por 15 minutos ( $s$ ). A patrulha poderá ainda ser despachada para ocorrência recebida pela central de operações. Neste caso, será calculado o tempo em trânsito até o local da ocorrência. Ela ficará no local da ocorrência pelo período necessário para seu atendimento ( $d$ ). Ao final deste período, estará livre para avançar para outro *hotspot* (vértice). Ao término da jornada de cada patrulha (6, 8 ou 12 horas), ela retorna ao ponto de partida.

**Quadro 3 - Funcionamento do sistema**

.	0	1	2	...	k
0	$V_{partida}$	$V_{partida}$	$V_{partida}$		$V_{partida}$
1	trânsito	trânsito	trânsito		trânsito
2	$v_a$ (parada)	trânsito	trânsito		trânsito
3	$v_a$ (parada)	trânsito	$v_c$ (parada)		trânsito
4	$v_a$ (parada)	$v_b$ (ocorrência)	$v_c$ (parada)		trânsito
5	$v_a$ (parada)	$v_b$ (ocorrência)	$v_c$ (parada)		$v_d$ (parada)
6	$v_a$ (parada)	$v_b$ (ocorrência)	$v_c$ (parada)		$v_d$ (parada)
7	$v_a$ (parada)	$v_b$ (ocorrência)	$v_c$ (parada)		$v_d$ (parada)
...	...	...	...		...
16	$v_a$ (parada)	$v_b$ (ocorrência)	$v_c$ (parada)		$v_d$ (parada)

17	trânsito	trânsito	$v_c$ (parada)	$v_d$ (parada)
18	trânsito	trânsito	trânsito	$v_d$ (parada)
19	trânsito	trânsito	trânsito	$v_d$ (parada)
20	$v_i$ (ocorrência)	trânsito	$v_c$ (parada)	trânsito
...	...	...	...	...
1438	trânsito	trânsito	trânsito	trânsito
1439	$V_{partida}$	$V_{partida}$	$V_{partida}$	$V_{partida}$

Fonte: elaboração própria.

Os resultados são apurados pelo cálculo da ociosidade média dos *hotspots*, do Índice de Precisão da Previsão e tempo de resposta às ocorrências. O acerto é assinalado pela ocorrência de evento criminal no *hotspot* em que foi prevista a parada da patrulha no momento de seu acontecimento. Em razão disso, dados de reais de ocorrências são usados para fins de validação do modelo.

## 6. APLICAÇÃO DO MODELO

No presente capítulo, será aplicado o modelo apresentado no capítulo antecedente, considerando os dados disponíveis.

### 6.1 CRIAÇÃO DOS HOTSPOTS

Conforme exposto no capítulo dedicado à contextualização, a pesquisa tratará da área de 9º Batalhão de Polícia Militar com circunscrição sobre o Centro Histórico e bairros adjacentes – Arquipélago, Azenha (parte), Bom Fim, Cidade Baixa, Farroupilha, Floresta, Independência, Moinhos de Vento, Praia de Belas (parte), Rio Branco, Santana (parte) e Santa Cecília – no Município de Porto Alegre. De acordo com dados do ObservaPOA (2018), a região possui 167.169 habitantes e ocupa 59,44 km<sup>2</sup>, correspondente a 11,86% da população e 11,96% da área da cidade, respectivamente, como pode ser visto na tabela abaixo:


**Tabela 1 - Dados demográficos de região de Porto Alegre**

Bairro	População	Domicílios	Área (km <sup>2</sup> )
Arquipélago	8.330	2.573	44,02
Azenha	13.804	5.943	1,39
Bom Fim	11.593	5.812	0,50
Centro Histórico	39.154	20.017	2,44
Cidade Baixa	15.379	8.301	0,76
Farroupilha	961	438	0,59
Floresta	11.596	4.784	1,87
Independência	8.112	4.001	0,44
Moinhos de Vento	11.937	5.423	1,31
Praia de Belas	2.281	1.000	2,57
Rio Branco	17.531	7.542	1,34
Santana	20.723	9.220	1,53
Santa Cecília	5.768	2.554	0,68
<b>Total</b>	<b>167.169,00</b>	<b>77.608,00</b>	<b>59,44</b>

Fonte: ObservaPOA (2018).

A região concentra o maior polo comercial e bancário da cidade. Abriga também boa parte da rede hoteleira, instituições de ensino importantes, museus e teatros. Além disso, ali se encontram as sedes dos poderes executivo, legislativo e

judiciário do Estado do Rio Grande do Sul, a Prefeitura, a Câmara de Vereadores e sedes de órgãos públicos e privados importantes. Estima-se a população flutuante de 400 mil habitantes nos dias úteis.



**Figura 6 - Área do 9ºBPM**

Fonte: elaboração própria. Usando: QGIS [Software QGIS]. Versão 3.16.7. QGIS Geographic Information System. Open Source Geospatial Foundation Project. <http://qgis.osgeo.org>, 2021.

O 9º BPM possui seus limites de área sobrepostos aos bairros acima mencionados, com exceção dos bairros Azenha, Praia de Belas e Santana, os quais são cortados pela Av. Ipiranga, via que serve de divisa para outras unidades da Brigada Militar. Ademais, registra-se que a unidade foi a primeira da Brigada Militar a sofrer processo de modernização do sistema de radiocomunicação, o que permitirá o acesso a dados de geolocalização das viaturas policiais (SECRETARIA DA SEGURANÇA PÚBLICA, 2021).

Quantos aos eventos criminais, será utilizada a base de chamados dos telefones de emergência e os registros policiais de crimes, ambos disponibilizados pela Secretaria da Segurança Pública do Estado do Rio Grande do Sul, classificadas por tipo de evento, data, hora, endereço e coordenadas geográficas. Adverte-se aqui sobre a possibilidade de eventos não registrados pelas vítimas, os quais podem comprometer a exatidão dos dados.

No decorrer do período em estudo, de 1º de janeiro de 2015 a 31 de dezembro de 2021, foram registrados 428.214 eventos policiais. Deste total 78,92%, 337.869,

foram eventos envolvendo ocorrências criminais. Nas bases consultadas, obtêm-se os dados do momento da ocorrência (data e hora), localização (logradouro, latitude e longitude) e de tipificação do fato (classificação conforme o Código Penal). Neste sentido, foi realizado refinamento dos dados obtidos do sistema SIAE e na base de registro policiais com os seguintes argumentos:

#### Quadro 4 - Argumentos de pesquisa nos sistemas

<b>Campo</b>	<b>Argumento</b>
SUBTIPO	Tabela de Crimes
Órgão	9º BPM
DATA/HORA CRIAÇÃO	01/01/2015 00:00:00 A 31/12/2021 23:59:59

Fonte: elaboração própria.

Em relação às estruturas notáveis, serão usados dados públicos da Prefeitura de Porto Alegre para a identificação de escolas, postos de saúde, hospitais e outros serviços de interesse, da Secretaria da Segurança Pública, quanto à localização de quartéis da Brigada Militar e câmeras de monitoramento, assim como, dados extraídos no sistema QGIS, via complemento QuickOSM, tais como, lojas, supermercados, pontos de ônibus, bares, etc. (TRIMAILLE, 2022). Estes últimos são registrados voluntariamente pelos usuários. Desta forma, podem não revelar precisamente a situação atual. Todos os dados são acompanhados de sua categorização como estrutura, endereço e coordenadas geográficas. Na tabela abaixo, constam os tipos e as origens dos dados a serem utilizados:

#### Quadro 5 - Lista de estruturas notáveis

<b>Número</b>	<b>Tipo</b>	<b>Origem</b>
1	Comércio (lojas, bancos, postos de gasolina, salões de beleza etc.).	Open Street Map
2	Bares e restaurantes	Open Street Map
3	Educação (escolas, faculdades etc.)	Open Street Map
4	Saúde (postos de saúde, hospitais, clínicas etc.)	Open Street Map
5	Estações do transporte público (ônibus e metrô).	Open Street Map
6	Parques e praças	Open Street Map
7	Câmeras de Cercamento Eletrônico	Prefeitura Municipal de Porto Alegre
8	Câmeras de Videomonitoramento	Secretaria da Segurança Pública
9	Câmeras de Videomonitoramento	Prefeitura Municipal de Porto Alegre

Nota: elaboração própria.

No sistema QGIS (QGIS DEVELOPMENT TEAM, 2021), os dados acima são carregados sobre mapa base. São introduzidas as camadas de bairros e unidades da Brigada Militar com as devidas circunscrições. Em seguida, são criados 474 grids (MALIK et al., 2014; PERRY et al., 2013; UBER TECHNOLOGIES, 2015), no formato de hexágono de 350 metros de lado sobre a área do 9º BPM. A referida dimensão é indicada, considerando-se que a região é composta de bairros densamente povoados, com exceção das ilhas.



**Figura 7 - Área do 9ºBPM - Grids Hexagonais (350 metros de lado)**

Fonte: elaboração própria – Usando: QGIS [Software QGIS]. Versão 3.16.7. QGIS Geographic Information System. Open Source Geospatial Foundation Project. <http://qgis.osgeo.org>, 2021.

Nos grids são introduzidos os locais dos eventos policiais ocorridos nos anos de 2015, 2016, 2017, 2018, 2019, 2020 e 2021, assim como, as estruturas notáveis. Na figura abaixo, para exemplificar, estão representados os *grids* (linhas azuis), os pontos marrons são os eventos de 2015 a 2021, os vermelhos restaurantes, os rosas



terminais de transporte público, os amarelos parques e os verdes escolas, como estruturas notáveis.



**Figura 8 - Ocorrências e estruturas notáveis na circunscrição dos Grids Hexagonais**

Fonte: elaboração própria. Usando: QGIS [Software QGIS]. Versão 3.16.7. QGIS Geographic Information System. Open Source Geospatial Foundation Project. <http://qgis.osgeo.org>, 2021.

Após a contagem de ocorrências, descartam-se os *grids* que não tiveram registros policiais no decorrer do período estudado. Restam 157 *grids*, os quais serão considerados para fins de definição de rotas de patrulhamento. Deste número foram selecionados os 50 com maior densidade, os quais passam a ser denominados de *hotspots*. Tais locais concentram 79,06% das ocorrências na área total estudada (267.118 eventos).



**Figura 9 - Área do 9ºBPM - Grids de interesse**

Fonte: elaboração própria. Usando: QGIS [Software QGIS]. Versão 3.16.7. QGIS Geographic Information System. Open Source Geospatial Foundation Project. <http://qgis.osgeo.org>, 2021.

Cada *hotspot* possui um local de referência  $v$  para parada da patrulha policial pelo período  $s$ . Os vértices  $v$  possuem coordenadas geográficas determinadas. A escolha dos  $n$  vértices leva em consideração a experiência policial, com vistas a garantir a maior visibilidade da presença da patrulha naquele local (cruzamentos e vias mais movimentadas). Na figura abaixo, constam os vértices eleitos em cada *grid*:



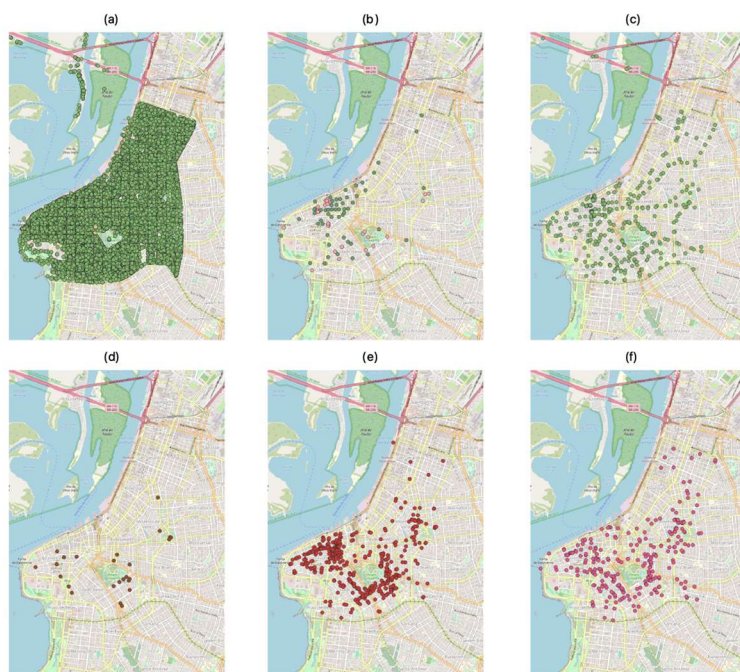
**Figura 10 - 50 hotspots e os respectivos locais de parada das patrulhas policiais.**

Fonte: elaboração própria. Usando: QGIS [Software QGIS]. Versão 3.16.7. QGIS Geographic Information System. Open Source Geospatial Foundation Project. <http://qgis.osgeo.org>, 2021.



## 6.2 ANÁLISE PREDITIVA DA CRIMINALIDADE

Demonstrados os procedimentos para determinação dos *hotspots* e *grids*, parte-se para análise preditiva, com vistas à identificação dos possíveis alvos da criminalidade. Para exemplificar, são considerados os eventos criminais, no período de 2015 a 2021, na área do 9º BPM, os quais totalizam 340.819 ocorrências. Considera-se o quantitativo dos aludidos crimes ocorridos num raio de 350 metros como variável independente e dependentes dados temporais e de estruturas notáveis, conforme detalhado na Seção 5.1.



**Figura 11 - (a) Eventos criminais de 2015 a 2021; (b) Câmeras de Vigilância; (c) Paradas de ônibus; (d) Escolas, Colégios e Universidades; (e) Estabelecimentos comerciais; (f) Bares e Restaurantes.**

Fonte: elaboração própria. Usando: QGIS [Software QGIS]. Versão 3.16.7. QGIS Geographic Information System. Open Source Geospatial Foundation Project. <http://qgis.osgeo.org>, 2021.

Os dados de treino e teste referem-se ao período de 1º de janeiro de 2015 a 30 de novembro de 2021. Os dados de treino e de teste foram escolhidos de forma aleatória, abrangendo 80% e 20%, respectivamente, do total de ocorrências disponíveis. Para a validação foram reservados os dados do período de 1º a 31 de dezembro de 2021.

Foi utilizado o método de árvore de decisão do XGBoost (CHEN; GUESTRIN, 2016) para a classificação dos dados temporais em estudo. Conforme levantamento realizado, o método obteve 64,85% de acurácia após a sua aplicação sobre os dados de teste. Os parâmetros e o grau de importância de cada um deles para a predição constam na tabela abaixo:

**Tabela 2 - Importância das variáveis para a predição**

<b>Variáveis</b>	<b>Participação</b>
Número de câmeras	13,82%
Número de paradas do transporte público	12,03%
Número de lojas (comércio em geral)	11,76%
Mês	8,86%
Dia ou noite	7,69%
Longitude	6,21%
Hotspot	5,27%
Latitude	5,13%
Hora	4,49%
Dia da semana	3,97%
Estação	3,93%
Ano	3,72%
Dia do mês	3,69%
Número de parques e praças	3,35%
Número de bares e restaurantes	3,07%
Número de instituições de ensino	2,94%

Fonte: elaboração própria.

Em relação a cada vértice (*hotspot*), tendo como parâmetros as variáveis independentes acima, o método preditivo calculou a previsão do número de ocorrências policiais para o período de validação (1º a 10 de dezembro de 2021), dia a dia, hora a hora. O valor normalizado Equação (3) será carregado no sistema como peso  $w_{h_i}$ , para cálculo do ganho de policiamento Equação (13).

### 6.3 DEFINIÇÃO DO CENÁRIO DE AVALIAÇÃO

Conforme já informado, os dados criminais obtidos são relativos ao período de 2015 a 2021. Separou-se os primeiros dez dias do mês de dezembro de 2021 para validação da experimentação sugerida.

Destaca-se que, em relação aos chamados policiais, estão disponíveis informações, quanto ao horário da chamada para os telefones de emergência, do

despacho de recurso para atendimento, chegada da viatura no local do fato e o encerramento da ocorrência.

Aplicar-se-á o modelo proposto com os dados de patrulhas policiais, considerando as ocorrências policiais dadas no período de 1º a 10 de dezembro de 2021. Durante o período ocorreram foram geradas 673 ocorrências para atendimento do 9º Batalhão de Polícia Militar. A média de tempo para o atendimento foi 28,84 minutos (diferença entre o despacho e a chegada da viatura), apresentando mínimo 0, quando a guarnição se depara com a ocorrência, e máximo 525 minutos de espera até a chegada da Polícia Militar. O desvio padrão ficou em 40,79 minutos.

De posse de tais dados, será possível pela simulação avaliar se a alocação dos recursos disponíveis para patrulhamento com o uso do método estabelecido determinará redução no tempo de resposta, em razão do posicionamento das patrulhas nos locais de maior incidência de ocorrência, conforme o método de predição. O tempo de resposta é dado pelo tempo decorrido da chamada para os telefones de emergência e a chegada da viatura no evento.

#### 6.4 ANÁLISE DOS RESULTADOS

A partir do cenário estabelecido na seção anterior disso, partiu-se a simulação das patrulhas policiais, buscando-se verificar os efeitos das constantes  $\alpha$ ,  $\beta$  e  $\theta$ , representativas da participação do feromônio, da distância e da importância do *hotspot* (predição), respectivamente.

Comparou-se o uso do ganho de policiamento (Equação 13) para decisão do próximo *hotspot* a ser patrulhado, aplicando-se graus diferentes de exponenciação ( $\theta$ ), com a escolha aleatória dos *hotspots* para patrulhamento.

Os resultados foram avaliados sob os seguintes enfoques:

- 1) Ociosidade média dos *hotspots*: é dada pelo tempo em que os *hotspots* ficam sem a presença policial. Por meio da ponderação dos *hotspots*, é possível privilegiar os pontos com maior densidade criminal. Nos trabalhos de Chen, Cheng e Wise (2015, 2017), trata-se da função objetivo.

- 2) Tempo de resposta às ocorrências: diz respeito ao tempo necessário para o atendimento da chamada somado ao deslocamento da viatura até a ocorrência (Equação 17).
- 3) Índice de Precisão da Previsão: trata dos acertos, quando a patrulha policial estava presente no hotspot quando o crime aconteceu.

Como ponto de partida, aplicou-se o Algoritmo 1 para a alocação das patrulhas para o patrulhamento e atendimento de ocorrências, sem o uso da estratégia multiagente, realizando as escolhas de forma aleatória. São considerados como pontos para direcionamento das patrulhas os 157 *hotspots* (figura 9), com o registro de pelos menos uma ocorrência no período de 2015 a 2021. Os resultados constam na tabela abaixo:

**Tabela 3 - Escolha Aleatória**

Variável de Desempenho		1	2	3	Média
Ociosidade (min)	Mínimo	175,61	167,44	189,47	177,51
	Máximo	378,95	369,23	342,86	363,68
	Média	250,48	250,15	248,38	249,67
	Desvio	45,35	38,36	39,97	41,22
Tempo de resposta (min)	Mínimo	0	0	0	0
	Máximo	74	35	23	44
	Média	3,73	3,35	3,58	3,55
	Desvio	4,21	3,07	3,23	3,50
Índice de Precisão da Previsão	Acertos	54	43	50	49
	Percentual	8,02%	6,39%	7,43%	7,28%

Fonte: elaboração própria.

A ociosidade média ficou em 249,67 minutos, ou seja, cada ponto, foi visitado a cada 4 horas e 9 minutos. O tempo de resposta médio para o atendimento de ocorrências foi de 3,55 minutos, no intervalo de 0 a 44 minutos. Em média, em 49 ocorrências, havia pelo menos uma patrulha na área do *hotspot* (hexágono), equivalente a 7,28% das ocorrências.

Em seguida, passou-se a aplicação do modelo proposto por Chen et al (2015, 2017), com introdução da variável  $w_{h_i}$  com a análise preditiva e as constantes  $\alpha$ ,  $\beta$  e  $\theta$ . A taxa de decaimento do feromônio foi estabelecida em 0,1. No anexo único, constam os resultados completos.

**Tabela 4 - Ociosidade Média**

$\alpha$	$\beta$	$\theta$				
		0,5	0	1	2	4
0	1	67,44	67,72	66,65	66,28	67,31
0,25	0,75	71,70	72,92	73,55	72,82	73,76
0,5	0,5	73,79	72,04	74,09	71,11	71,78
0,75	0,25	72,96	71,88	74,47	73,57	76,06
1	0	74,27	74,80	75,24	74,15	74,79

Fonte: elaboração própria.

Na tabela acima, estão os dados relativos à ociosidade média nos 50 *hotspots* escolhidos. Os valores menores indicam maior número de visitas pelas patrulhas no total. Conforme, aumenta-se  $\alpha$  e diminui-se  $\beta$ , a tendência é a subida do tempo de ociosidade média, ou seja, a redução de visitas, ao passo que se privilegia a diversificação dos *hotspots* a serem visitados, em detrimento dos pontos mais próximos. A menor ociosidade média se deu em  $\alpha = 0$ ,  $\beta = 1$  e  $\theta = 2$ .

**Tabela 5 - Tempo-Resposta Médio**

$\alpha$	$\beta$	$\theta$				
		0,5	0	1	2	4
0	1	1,98	2,05	2,04	1,99	1,93
0,25	0,75	2,03	2,09	2,02	2,45	2,39
0,5	0,5	2,16	2,02	1,87	2,47	2,30
0,75	0,25	2,00	2,15	2,32	1,98	2,19
1	0	2,10	2,15	2,39	2,29	1,93

Fonte: elaboração própria.

O tempo-resposta para o atendimento de ocorrências (Tabela 5) tem comportamento diferente da ociosidade. Os menores valores para o tempo-resposta indicam a melhor disposição das patrulhas para o atendimento das ocorrências. Os melhores resultados se concentraram na diagonal principal. Para  $\alpha = 0,5$ ,  $\beta = 0,5$  e  $\theta = 1$ , tem-se o menor tempo-resposta: 1,87 minuto.

Tabela 6 – Índice de Precisão da Previsão

$\alpha$	$\beta$	$\theta$				
		0,5	0	1	2	4
0	1	28,53%	26,30%	27,34%	27,04%	30,76%
0,25	0,75	25,85%	27,64%	26,89%	16,64%	20,36%
0,5	0,5	25,71%	26,00%	28,68%	19,47%	22,73%
0,75	0,25	27,79%	24,52%	19,91%	25,41%	25,41%
1	0	24,52%	23,48%	21,99%	23,18%	27,34%

Fonte: elaboração própria.

O Índice de Precisão da Previsão (Tabela 6) possui comportamento parecido com o Tempo-Resposta Médio (Tabela 5), quanto à disposição dos resultados, frente às constantes. O acerto corresponde ao estado em que a patrulha se encontra no *hotspot* do local do evento criminoso no instante de sua ocorrência. O melhor resultado foi obtido com  $\alpha = 0$ ,  $\beta = 1$  e  $\theta = 4$  (30,76%).

## 6.5 DISCUSSÃO

O modelo apresentado (tabelas 4, 5 e 6) mostrou-se bastante superior à estratégia de escolha aleatória dos *hotspots* a serem patrulhados (tabela 3). A maior eficiência justifica-se, inicialmente, pelo processo de separação dos *hotspots*, com maior incidência de crimes com base no princípio de Pareto. A ênfase das patrulhas foi sobre os locais que concentram 80% das ocorrências. As patrulhas deslocaram para outras áreas somente em decorrência do atendimento de ocorrências.

Os resultados, usando-se o modelo original proposto por Chen, Cheng e Wise (2015, 2017), são obtidos com  $\alpha = 0$ ,  $\beta = 1$  e  $\theta = 0$ . Neste sentido, em comparação, destaca-se que a aplicação de valores diferentes para  $\theta$  (0,5; 1; 2 e 4) obteve valores menores de ociosidade média e do tempo de resposta médio, assim como, os índice de acertos foi superior. Reforça o melhor desempenho do modelo proposto.

Quanto à possibilidade do modelo se adaptar dinamicamente frente a ocorrências policiais, também se verificou avanço em relação ao modelo de Chen, Cheng e Wise (CHEN; CHENG; WISE, 2015, 2017). Conforme, surgiam ocorrências, o sistema buscava a patrulha mais próxima, considerando o tempo de deslocamento de cada patrulha e sua velocidade relativa, seja no processo a pé, de bicicleta e motorizado (carro ou motocicleta).



**Figura 12 - Rota de patrulha**

Fonte: elaboração própria com o uso da API BING MAPS (2022).

**Quadro 6 - Descrição da rota de patrulha**

Início	Fim	Atividade	Vértice
0	0	Depósito	52
1	1	Trânsito	
2	17	Patrulhamento	5
18	18	Trânsito	
19	34	Patrulhamento	1
35	35	Trânsito	
36	67	Patrulhamento	3
35	35	Trânsito	
36	67	Patrulhamento	6
68	69	Trânsito	
70	85	Patrulhamento	12
86	89	Trânsito	
90	90	Patrulhamento	30
91	169	Ocorrência	30
170	172	Trânsito	
173	188	Patrulhamento	25
189	189	Trânsito	
190	205	Patrulhamento	40
206	206	Trânsito	
207	222	Patrulhamento	31
223	225	Trânsito	

226	241	Patrulhamento	13
242	242	Trânsito	
243	258	Patrulhamento	15
259	274	Patrulhamento	21
275	275	Trânsito	
276	291	Patrulhamento	22
292	293	Trânsito	
294	309	Patrulhamento	42
310	312	Trânsito	
313	328	Patrulhamento	46
329	331	Trânsito	
332	347	Patrulhamento	23
348	359	Trânsito	
360	375	Patrulhamento	48
376	384	Trânsito	
385	400	Patrulhamento	1
401	417	Trânsito	
418	420	Depósito	52

Fonte: elaboração própria

Para exemplificar, na figura 12 e no quadro 6, verifica-se a rota gerada minuto a minuto para uma patrulha  $r$ . Ela entrou de serviço no minuto 0, a partir do depósito no vértice 52, com jornada de 420 minutos. Percorreu os *hotspots* descritos no quadro 6, atendeu à ocorrência no minuto 91, no *hotspot* relativo ao vértice 30. Iniciou retorno para o depósito no tempo 401, chegando no 9º BPM (vértice 52) no tempo 418, dois minutos antes do término do turno. O caminho descrito é factível, possibilitando a sua execução em cenário real.

**Tabela 7 - Comparação do Tempo-Resposta**

Real	Aleatório	Proposto
28,84	3,55	1,87

Fonte: elaboração própria.

Em relação às informações de emprego reais do policiamento, os dados apresentados somente podem ser comparados no tocante ao tempo resposta no atendimento das ocorrências (Tabela 7). Não há dados sobre os tempos de parada em patrulhamento em pontos específicos para fins de registro da ociosidade. Os valores colhidos do sistema público, quanto ao atendimento de chamados, pode sofrer distorções em decorrência do momento de registro da chegada na ocorrência e de



seu encerramento pelos policiais. Além disso, a simulação considerou todos os recursos policiais como disponíveis para ocorrência. Contudo, isto não acontece no mundo real. Há patrulhas fixadas em pontos e atividades específicas, não ficando disponíveis para atendimento de ocorrências. Outro ponto a ser considerado é que a simulação considerou as distâncias entre os vértices relacionados a cada *hotspot*. Ou seja, para um a ocorrência no *hotspot*  $j$  partindo do *hotspot*  $i$  foram aplicadas as distâncias da matriz  $M = V \times V$ , o que pode gerar inexatidão.

Para a geração das rotas de patrulhamento e para o atendimento de ocorrências, a manutenção em memória de matriz de distâncias parece o mais adequado, a fim de dar agilidade a resposta do sistema. Contudo, em cenário real, a requisição da rota aos sistemas de roteamento disponíveis na Internet no momento do despacho da patrulha parece ser o mais aconselhado, pois relevará bloqueios, desvios, congestionamentos etc., no momento da alocação do recurso.

Diferentemente da estratégia de alocação aleatória de viaturas para o patrulhamento dos *hotspots* e o atendimento de ocorrências, no modelo proposto há mecanismos voltados à diminuição da ociosidade nos *hotspots*. Na forma aleatória, a média de ociosidade foi de 249,67 minutos. Contudo, nesta as patrulhas podem visitar todos os 155 *hotspots* e não somente os 50 escolhidos, seguindo o Princípio de Pareto. A diferença essencial se mostra no tempo-reposta e o número de acertos. O modelo proposto permite um tempo de resposta 89,83% menor que o aleatório, e os acertos dos locais onde acontecerão as ocorrências em 30,76% dos casos contra 8,02% (melhores casos), resultados bastante superiores.

Destaca-se, no entanto, a necessidade de aprimoramento do modelo preditivo e adoção de outros algoritmos capazes de melhorar os resultados sobre a base disponibilizada. A seleção de variáveis (PERRY et al., 2013) deve sofrer aperfeiçoamento para garantir o afastamento de perturbações do resultado, em razão de sobreajuste (*overfitting*). Como visto, o modelo obteve 64,85% de acurácia em teste, superior aos resultados da proposta.

É importante salientar que a precisão da previsão sofreu interferências da função ganho de policiamento, Equação (8), modificada pelo autor, e do registro de visitas, por meio do feromônio. As constantes  $\alpha$  e  $\beta$  possibilitaram aumentar ou diminuir o impacto do feromônio e da distância normalizada na formação do ganho de policiamento. Contudo, ao passo que o feromônio sofria o decaimento, a cada minuto nos *hotspots*, maior se torna a pressão para sua alocação, mesmo aumentando-se o

peso da predição  $\theta$ . Ademais, a visita de *hotspots* mais distantes reduz o tempo disponível para outras visitas, aumentando a ociosidade dos pontos e o risco do incremento no tempo-resposta. Desta forma, mudanças sutis das constantes de entrada podem determinar mudanças significativas no resultado.

## 7 CONCLUSÃO

Conforme os resultados apresentados, por meio de simulação, pode-se afirmar que é possível estabelecer sistema de otimização dinâmico de roteamento de patrulhas policiais para minimização da ociosidade nos *hotspots* e do tempo de resposta no atendimento de ocorrências, inspirado em estratégia multiagente, sabendo-se que as patrulhas operam em jornadas de serviço determinadas e movimentos controlados por central de operações, a fim de realizar o atendimento de ocorrências e ações preventivas de patrulhamento e permanência, em pontos de maior densidade de ocorrências e estruturas notáveis, considerando-se a análise preditiva sobre dados históricos por horário, dia da semana e mês do ano.

O modelo desenvolvido permite avaliar a influência de fatores dinâmicos, relacionados ao tempo e a estruturas notáveis presentes na área de estudo. E são significativos, sendo necessárias adaptações recorrentes na formulação de rotas para atender aos pontos mais críticos. O horizonte de planejamento foi de 10 dias (1º a 10 de dezembro de 2021), considerando o esforço computacional para geração dos resultados. A mudança da dinâmica da simulação de discreta (minuto a minuto) para orientada por eventos pode melhorar a eficiência computacional e permitir a análise em período maior.

A estratégia multiagente de policiamento propiciou melhor tratamento a questões relacionadas a ociosidade, quanto à presença policial em pontos importantes, assim como, a coordenação de patrulhas com características diferentes, a fim de evitar a sobreposição de recursos. As patrulhas possuíam horários de emprego, jornadas de trabalho e velocidades de deslocamento diferentes, o que foi necessariamente tratado pelo algoritmo sugerido, como forma otimizar o modelo. Ademais, a estratégia ganho de policiamento com pesos obtidos em análise preditiva apresentou bons resultados, ao passo que evita a previsão do comportamento policial por agentes criminosos inteligentes.

No entanto, a função objetivo do modelo, centrada no feromônio (histórico de visitas), distância mínima e predição pode ser aperfeiçoada para a maximização da utilidade de estados (VLASSIS, 2007), ou mesmo até mesmo, o desenvolvimento de método com aprendizado por reforço, com a gestão de sistema de recompensas,

conforme as atividades desenvolvidas pelas patrulhas (RUMI; QIN; SALIM, 2020; RUMI; SHAO; SALIM, 2020). O desafio está em determinar matematicamente a utilidade do patrulhamento policial, considerando que a base empírica existente não é satisfatória para determinar a contribuição da presença policial, seja para afastar as ameaças do acontecimento do crime ou no sentimento de tranquilidade das pessoas (SHERMAN, 1990), especialmente, no tempo. Ademais, os *coldspots* (TAYEBI et al., 2014), locais com menor risco de eventos criminais, considerando o histórico, devem ser tratados, a fim de, até mesmo, se evitar a transferência dos locais de manifestação da criminalidade.

De posse de dados temporais e geográficos do espaço estudado, foi possível desenvolver modelo preditivo, o qual foi aplicado como peso para dimensionamento da ênfase na aplicação dos recursos policiais no patrulhamento. Além disso, permitiu maior assertividade na escolha dos pontos com maior de risco de ocorrência de novos eventos policiais (*hotspots*). A relevância das ocorrências dadas nos últimos 30 dias e 7 dias (RUMI; QIN; SALIM, 2020) pode ser aprimoramento importante para melhoramento do modelo.

O modelo foi validado com dados reais de ocorrências e de recursos operacionais em uma unidade policiamento ostensivo da cidade de Porto Alegre. Foi possível demonstrar que o emprego modelo pode trazer significativa melhora na distribuição do policiamento na área, com redução da ociosidade dos *hotspots* e redução do tempo de resposta nos casos de ocorrências policiais. Caso empregado em situações reais, pode determinar redução na criminalidade e o aumento da sensação de segurança das comunidades abrangidas.

O Índice de Precisão da Previsão e o tempo de resposta para o atendimento de ocorrências podem ser melhorados. Destaca-se que o modelo preditivo obteve acurácia de 64,85% com dados de teste, enquanto, que no processo de validação o valor máximo de acertos foi de 30,76%. A simulação empregou os recursos disponíveis, nas datas, horários e jornadas do planejamento operacional posto. Contribuiu na definição dos locais de patrulhamento e parada, assim como, na escolha da patrulha mais próxima para atendimento de ocorrência. Contudo, a definição dos horários e dias de maior concentração dos recursos operacionais refoge ao escopo desta pesquisa, o que pode certamente determinar melhorias nos resultados.

Cabe destacar, entretanto, que o modelo certamente não relevou todas as restrições presentes na realidade, devendo sofrer aperfeiçoamentos. Para

exemplificar, registra-se que o modelo proposto não tratou de patrulhas dedicadas a atender eventos criminais específicos, tais como, as patrulhas Maria da Penha, dirigidas à violência doméstica, e a patrulhas escolares, dedicadas aos crimes relacionados às instituições de ensino. Além disso, não tratou dos afastamentos das patrulhas de suas atividades normais, em razão da necessidade de alimentação, necessidades fisiológicas, reabastecimento de veículos etc.

O valor reduzido no tempo médio para o atendimento de ocorrências, apresentado como resultado do modelo, pode estar relacionado a fixação de efetivos em pontos específicos e restrição no despacho para o atendimento de ocorrência para parte das patrulhas disponíveis. Ademais, o tempo de resposta pode ter sofrido distorções pela velocidade média em cada processo (a pé, motorizado - carro ou motocicleta-, bicicleta), as quais foram fixadas em valor de referência para facilitar os cálculos de custo tempo entre os vértices nos *hotspots*. Na aplicação em tempo real, os caminhos podem ser requisitados no momento de sua necessidade, considerando-se então o contexto atual do trânsito do local de emprego, dando maior previsão na definição dos custos de deslocamento.

Neste sentido, a área de estudo do problema de patrulhamento policial parece ser campo fértil para novas pesquisas. A aplicação de métodos preditivos, nas áreas de *machine learning* e *deep learning*, podem propiciar previsões mais precisas dos horários e locais em que os crimes podem acontecer. A disponibilização de dados de localização dos agentes e de ferramentas de roteamento precisas podem propiciar melhorias em tempo real no atendimento de ocorrências. A coleta de dados mais abrangentes sobre o funcionamento de atividades privadas (bares, restaurantes, clínicas etc.) e públicas (parques, hospitais, escolas etc.) podem permitir o aprimoramento das previsões. Além disso, o conhecimento mais aprofundado sobre as peculiaridades do funcionamento do serviço policial certamente permitirá a definição de restrições que levem a modelagem mais próxima da realidade e capaz de trazer melhores resultados.

## REFERÊNCIAS

- ALMANIE, T.; MIRZA, R.; LOR, E. Crime Prediction Based on Crime Types and Using Spatial and Temporal Criminal Hotspots. **International Journal of Data Mining & Knowledge Management Process**, v. 5, n. 4, p. 01–19, 2015.
- ALMEIDA, A. et al. Recent Advances on Multi-agent Patrolling. Em: [s.l.] Springer, Berlin, Heidelberg, 2004. p. 474–483.
- ALMEIDA, A. DE L. **Patrulhamento Multiagente em Grafos com Pesos**. Recife: [s.n.]. Disponível em: <[www.cin.ufpe.br/~posgraduacao](http://www.cin.ufpe.br/~posgraduacao)>. Acesso em: 25 mar. 2023.
- ANDRADE, E. L. **Introdução à Pesquisa Operacional - Método e Modelos para Análise de Decisões**. 5ª ed. Rio de Janeiro: [s.n.].
- MICROSOFT CORPORATION. **API Bing Maps**. Microsoft, , 2022. Disponível em: <<https://www.microsoft.com/en-us/maps/choose-your-bing-maps-api>>. Acesso em: 25 mar. 2023
- BELFIORE, P.; FÁVERO, L. P. **Pesquisa Operacional para cursos de Administração, Contabilidade e Economia**. Rio de Janeiro: Elsevier, 2012.
- BERNÁBE LORANCA, B. et al. Implementation of Police Patrols based on an Intelligent Model of VRP. **Research in Computing Science**, v. 145, n. 1, p. 175–185, 31 dez. 2017.
- BLOCK, C. R. STAC hot spot area: a statistical tool for law enforcement actions. **Meetings on Environmental Criminology**, p. 1–20, 1993.
- BORENSTEIN, D. Towards a practical method to validate decision support systems. **Decision Support Systems**, v. 23, n. 3, p. 227–239, jul. 1998.
- BRAGA, A. A. Hot spots policing and crime prevention: A systematic review of randomized controlled trials. **Journal of Experimental Criminology**, v. 1, n. 3, p. 317–342, 15 set. 2005.
- BRANTINGHAM, P.; BRANTINGHAM, P. Criminality of place. **European Journal on Criminal Policy and Research**, v. 3, n. 3, p. 5–26, set. 1995.
- BOTTOMS, A. E.; WILES, P. Environmental Criminology. Em: **Crime, Inequality and the State**. [s.l.] Routledge, 2020. p. 273–293.
- BRASIL. **Constituição da República Federativa do Brasil**. Disponível em: <[http://www.planalto.gov.br/ccivil\\_03/constituicao/constituicao.htm](http://www.planalto.gov.br/ccivil_03/constituicao/constituicao.htm)>. Acesso em: 15 mar. 2022a.

BRASIL. **Decreto-Lei nº 667, de 2 de julho de 1969**. Disponível em: <[http://www.planalto.gov.br/ccivil\\_03/decreto-lei/del0667.htm](http://www.planalto.gov.br/ccivil_03/decreto-lei/del0667.htm)>. Acesso em: 15 mar. 2022b.

BRIGADA MILITAR. **Diretriz Geral da Brigada Militar nº 003/BM/EMBM/2001**. Brasil, 2001.

BRIGADA MILITAR. **Diretriz Geral da Brigada Militar nº 027/BM/EMBM/2013**. Brasil, 2013.

BRIGADA MILITAR. **Programa Avante**. Disponível em: <<https://antigo.bm.rs.gov.br/Servicos/Avante>>. Acesso em: 15 mar. 2022.

BRIGADA MILITAR. **História**. Disponível em: <<https://www.brigadamilitar.rs.gov.br/historia>>. Acesso em: 15 mar. 2022.

BRUSSEL, H. et al. **Mechanisms and Military Applications for Synthetic Pheromones**. Montreal: Proceedings of Workshop on Autonomy Oriented Computation, maio 2001. Disponível em: <[https://www.researchgate.net/publication/2352791\\_Mechanisms\\_and\\_Military\\_Applications\\_for\\_Synthetic\\_Pheromones](https://www.researchgate.net/publication/2352791_Mechanisms_and_Military_Applications_for_Synthetic_Pheromones)>. Acesso em: 25 mar. 2023

CAPLAN, J. M.; KENNEDY, L. W.; MILLER, J. Risk Terrain Modeling: Brokering Criminological Theory and GIS Methods for Crime Forecasting. **Justice Quarterly**, v. 28, n. 2, p. 360–381, 2011.

CHAINEY, S.; TOMPSON, L.; UHLIG, S. The Utility of Hotspot Mapping for Predicting Spatial Patterns of Crime. **Security Journal**, v. 21, n. 1–2, p. 4–28, 29 fev. 2008.

CHAWATHE, S. S. **Organizing Hot-Spot Police Patrol Routes**. 2007 IEEE Intelligence and Security Informatics. **Anais...IEEE**, maio 2007. Disponível em: <<http://ieeexplore.ieee.org/document/4258678/>>. Acesso em: 25 mar. 2023

CHEN, H.; CHENG, T.; WISE, S. DESIGNING DAILY PATROL ROUTES FOR POLICING BASED ON ANT COLONY ALGORITHM. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. II-4/W2, n. 4W2, p. 103–109, 10 jul. 2015.

CHEN, H.; CHENG, T.; WISE, S. Developing an online cooperative police patrol routing strategy. **Computers, Environment and Urban Systems**, v. 62, p. 19–29, 2017.

CHEN, T.; GUESTIN, C. **XGBoost**. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. **Anais...New York, NY, USA: ACM**, 13 ago. 2016. Disponível em: <<https://dl.acm.org/doi/10.1145/2939672.2939785>>. Acesso em: 25 mar. 2023

CHEVALEYRE, Y.; SEMPÉ, F.; RAMALHO, G. A theoretical analysis of multi-agent patrolling strategies. **Proceedings of the Third International Joint Conference on Autonomous Agents and Multiagent Systems, AAMAS 2004**, v. 4, p. 1524–1525, 2004.

COHEN, L. E.; FELSON, M. Social Change and Crime Rate Trends: A Routine Activity Approach. **American Sociological Review**, v. 44, n. 4, p. 588, ago. 1979.

DASH, S. K.; SAFRO, I.; SRINIVASAMURTHY, R. S. Spatio-temporal prediction of crimes using network analytic approach. **2018 IEEE International Conference on Big Data (Big Data)**, p. 1912–1917, 19 ago. 2018.

DEWINTER, M. et al. Analysing the Police Patrol Routing Problem: A Review. **ISPRS International Journal of Geo-Information**, v. 9, n. 3, p. 157, 9 mar. 2020.

DORIGO, M. et al. Positive Feedback as a Search Strategy. **Technical Report 91-016**, n. June, p. 1–20, abr. 1991.

ECK, J.; WEISBURD, D. Crime places in crime theory. **Crime and Place: Crime Prevention Studies**, 4, p. 1–33, 2015.

FU, J. G. M.; ANG, M. H. **Probabilistic Ants (PAnts) in Multi-Agent Patrolling**. 2009 IEEE/ASME International Conference on Advanced Intelligent Mechatronics. **Anais...IEEE**, jul. 2009. Disponível em: <<https://ieeexplore.ieee.org/document/5229880/>>. Acesso em: 25 mar. 2023

GETIS, A.; ORD, J. K. The Analysis of Spatial Association by Use of Distance Statistics. **Geographical Analysis**, v. 24, n. 3, p. 189–206, 3 set. 2010.

GODWIN, A.; STASKO, J. **HotSketch: Drawing Police Patrol Routes among Spatiotemporal Crime Hotspots**. Proceedings of the 50th Hawaii International Conference on System Sciences (2017). **Anais...2017**. Disponível em: <<http://hdl.handle.net/10125/41317>>. Acesso em: 25 mar. 2023

GONZALEZ, A. **ANALYZING THE RELATIONSHIP BETWEEN CRIME AND TREE CANOPY IN AUSTIN, TEXAS**. Tucson: [s.n.]. Disponível em: <<http://hdl.handle.net/10150/667143>>. Acesso em: 25 mar. 2023.

GOOS, G.; HARTMANIS, J.; VAN LEEUWEN, J. **Multi-Agent-Based Simulation II**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2003. v. 2581

IBM. **IBM Cognos**. IBM, , 2022.

KOPER, C. S. Just enough police presence: Reducing crime and disorderly behavior by optimizing patrol time in crime hot spots. **Justice Quarterly**, v. 12, n. 4, p. 649–672, dez. 1995.

LACHTERMACHER, G. **Pesquisa Operacional na Tomada de Decisões**. Rio de Janeiro: GEN LTC, 2018.

LEIGH, J.; DUNNETT, S.; JACKSON, L. Predictive police patrolling to target hotspots and cover response demand. **Annals of Operations Research**, v. 283, n. 1–2, p. 395–410, 25 dez. 2019.

LI, L. et al. Police patrol service optimization based on the spatial pattern of hotspots. **Proceedings of 2011 IEEE International Conference on Service Operations, Logistics and Informatics, SOLI 2011**, p. 45–50, 2011.



LI, L. et al. **Police Patrol service optimization based on the spatial pattern of hotspots**. Proceedings of 2011 IEEE International Conference on Service Operations, Logistics and Informatics. **Anais...IEEE**, jul. 2011. Disponível em: <<http://ieeexplore.ieee.org/document/5986526/>>. Acesso em: 25 mar. 2023

LONGARAY, A. A. **Introdução à Pesquisa Operacional**. . São Paulo: Saraiva, 2013.

MACIEJEWSKI, R. et al. Forecasting Hotspots—A Predictive Analytics Approach. **IEEE Transactions on Visualization and Computer Graphics**, v. 17, n. 4, p. 440–453, abr. 2011.

MALIK, A. et al. Proactive Spatiotemporal Resource Allocation and Predictive Visual Analytics for Community Policing and Law Enforcement. **IEEE Transactions on Visualization and Computer Graphics**, v. 20, n. 12, p. 1863–1872, 31 dez. 2014.

MCKINNEY, W. **Data Structures for Statistical Computing in Python**. 2010. Disponível em: <<https://conference.scipy.org/proceedings/scipy2010/mckinney.html>>. Acesso em: 25 mar. 2023

MENEZES, B. L. S. et al. UM MODELO DE ROTEIRIZAÇÃO PARA RONDAS ESCOLARES PREVENTIVAS DA GUARDA MUNICIPAL. Em: **LXVI Simposio Brasileiro De Pesquisa Operacional**. [s.l: s.n.]. p. 557–567.

INSPETORIA GERAL DAS POLÍCIAS MILITARES. **Manual Básico de Policiamento Ostensivo**. , 1993.

OBSERVAPOA. **Bairros novos têm cálculo de habitantes concluído**. Disponível em: <[http://www.observapoa.com.br/default.php?reg=536&p\\_secao=17](http://www.observapoa.com.br/default.php?reg=536&p_secao=17)>. Acesso em: 6 maio. 2022.

PERRY, W. L. et al. **Predictive Policing - The Role of Crime Forecasting in Law Enforcement Operations**. Santa Monica: RAND Corporation, 2013.

PILLAC, V. et al. A review of dynamic vehicle routing problems. **European Journal of Operational Research**, v. 225, n. 1, p. 1–11, fev. 2013.

PORTUGAL, D.; ROCHA, R. P. Distributed multi-robot patrol: A scalable and fault-tolerant framework. **Robotics and Autonomous Systems**, v. 61, n. 12, p. 1572–1587, dez. 2013.

RATCLIFFE, J. H. Aoristic Signatures and the Spatio-Temporal Analysis of High Volume Crime Patterns. **Journal of Quantitative Criminology**, p. 23–43, 2002.

REIS, D. et al. GAPatrol: An Evolutionary Multiagent Approach for the Automatic Definition of Hotspots and Patrol Routes. Em: **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**. [s.l: s.n.]. v. 4140 LNAlp. 118–127.

REIS, D. et al. Towards Optimal Police Patrol Routes with Genetic Algorithms. Em: **Lecture Notes in Computer Science (including subseries Lecture Notes in**

**Artificial Intelligence and Lecture Notes in Bioinformatics**). [s.l: s.n.]. v. 3975 LNCSp. 485–491.

RUAN, S. et al. Patrolling in a stochastic environment. **10th International Command and Control Research and Technology Symposium**, v. 1, p. 11, 2005.

RUMI, S. K.; QIN, K. K.; SALIM, F. D. Multi-officer Routing for Patrolling High Risk Areas Jointly Learned from Check-ins, Crime and Incident Response Data. p. 1–21, 2020.

RUMI, S. K.; SHAO, W.; SALIM, F. D. Realtime Predictive Patrolling and Routing with Mobility and Emergency Calls Data. **Proceedings of the International AAAI Conference on Web and Social Media**, v. 14, n. Icwsm, p. 964–968, 26 maio 2020.

SAINT-GUILLAIN, M.; PAQUAY, C.; LIMBOURG, S. Time-dependent stochastic vehicle routing problem with random requests: Application to online police patrol management in Brussels. **European Journal of Operational Research**, v. 292, n. 3, p. 869–885, ago. 2021.

SCHIFFER, A. **Recent Violent Crime Dynamics and Spatial Patterns in Albuquerque, New Mexico**. Tucson: [s.n.]. Disponível em: <<http://hdl.handle.net/10150/636388>>. Acesso em: 25 mar. 2023.

SECRETARIA DA SEGURANÇA PÚBLICA. **SSP amplia utilização de radiocomunicação digital para atendimentos da Brigada Militar**. Disponível em: <<https://ssp.rs.gov.br/ssp-amplia-utilizacao-de-radiocomunicacao-digital-para-atendimentos-da-brigada-militar>>. Acesso em: 25 mar. 2023.

SHERMAN, L. W. **Police Crackdowns: Initial and Residual Deterrence**. [s.l: s.n.]. v. 12

STEINMAN, H. et al. Risky Business: Examining the 80-20 Rule in Relation to a RTM Framework. **Criminal Justice Review**, v. 46, n. 1, p. 20–39, 22 mar. 2021.

STONE, P.; VELOSO, M. Multiagent systems: a survey from a machine learning perspective. **Autonomous Robots**, v. 8, n. 3, p. 345–383, 2000.

TAO, N.; CHEN, G.; TAO, N. **Solving VRP Using Ant Colony Optimization Algorithm**. 2012 Fifth International Conference on Information and Computing Science. **Anais...IEEE**, jul. 2012. Disponível em: <<http://ieeexplore.ieee.org/document/6258059/>>. Acesso em: 25 mar. 2023

TAYEBI, M. A. et al. **CRIMETRACER: Activity space based crime location prediction**. 2014 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM 2014). **Anais...IEEE**, ago. 2014. Disponível em: <<http://ieeexplore.ieee.org/document/6921628/>>. Acesso em: 25 mar. 2023

QGIS DEVELOPMENT TEAM. **QGIS - Geographic Information System API Documentation. Open Source Geospatial Foundation Project**. , 2021. Disponível em: <[https://qgis.org/pt\\_BR/site/](https://qgis.org/pt_BR/site/)>. Acesso em: 25 mar. 2023

- TRIMAILLE, E. **QuickOSM**. , 2022. Disponível em: <<https://docs.3liz.org/QuickOSM/>>. Acesso em: 25 mar. 2023
- TSAL, J. et al. Urban security: Game-theoretic resource allocation in networked physical domains. **Proceedings of the National Conference on Artificial Intelligence**, v. 2, p. 881–886, 2010.
- UBER TECHNOLOGIES. **H3 Hexagonal hierarchical geospatial indexing system**. Disponível em: <<https://h3geo.org/>>. Acesso em: 25 mar. 2023.
- VAN ROSSUM, G.; DRAKE JR, F. L. **Python reference manual**. Disponível em: <<https://ir.cwi.nl/pub/5008>>. Acesso em: 25 fev. 2023.
- VIRGILLITO, S. B. **Pesquisa operacional**. São Paulo: Saraiva, 2017.
- VLASSIS, N. A Concise Introduction to Multiagent Systems and Distributed Artificial Intelligence. **Synthesis Lectures on Artificial Intelligence and Machine Learning**, v. 1, n. 1, p. 1–71, jan. 2007.
- WEISBURD, D. et al. REFORMING TO PRESERVE: COMPSTAT AND STRATEGIC PROBLEM SOLVING IN AMERICAN POLICING\*. **Criminology & Public Policy**, v. 2, n. 3, p. 421–456, jul. 2003.
- WIANDT, B.; SIMON, V. **Autonomous Graph Partitioning for Multi-Agent Patrolling Problems**. Proceedings of the 2018 Federated Conference on Computer Science and Information Systems, FedCSIS 2018. **Anais...Institute of Electrical and Electronics Engineers Inc.**, 26 set. 2018. Disponível em: <<https://ieeexplore.ieee.org/document/8511293>>. Acesso em: 25 mar. 2023
- XU CHEN. Fast Patrol Route Planning in Dynamic Environments. **IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans**, v. 42, n. 4, p. 894–904, jul. 2012.
- XU CHEN; YUM, T.-S. P. **Cross Entropy approach for patrol route planning in dynamic environments**. 2010 IEEE International Conference on Intelligence and Security Informatics. **Anais...IEEE**, 2010. Disponível em: <<http://ieeexplore.ieee.org/document/5484767/>>. Acesso em: 25 mar. 2023
- YASSEN, E. T. et al. A Constructive Heuristic for Police Patrol Routing Problems. n. March, 2018.
- YU, C.-H. et al. **Crime Forecasting Using Data Mining Techniques**. 2011 IEEE 11th International Conference on Data Mining Workshops. **Anais...IEEE**, dez. 2011. Disponível em: <<http://ieeexplore.ieee.org/document/6137459/>>. Acesso em: 25 mar. 2023
- ZHANG, Y.; BROWN, D. E. Police patrol districting method and simulation evaluation using agent-based model & GIS. **Security Informatics**, v. 2, n. 1, p. 7, 2 dez. 2013.

## ANEXO ÚNICO

## Aplicação do Modelo

$\alpha$	$\beta$	$\theta$				
		0,5	0	1	2	4
Ociosidade	Mínimo	60,25	62,34	59,02	54,75	44,44
	Máximo	75,39	74,61	75,79	77,84	85,71
	Média	67,44	67,72	66,65	66,28	67,31
	Desvio	3,30	2,94	3,84	4,86	8,04
Tempo-Resposta	Mínimo	0	0	0	0	0
	Máximo	21	23	47	23	20
	Média	1,98	2,05	2,04	1,99	1,93
	Desvio	2,66	2,77	3,27	2,55	2,69
Acertos	Total	192	177	184	182	207
	Taxa	0,29	0,26	0,27	0,27	0,31

$\alpha$	$\beta$	$\theta$				
		0,5	0	1	2	4
Ociosidade	Mínimo	64,86	67,92	64,86	60,76	54,14
	Máximo	75,39	75,79	78,26	80,00	84,71
	Média	71,70	72,92	73,55	72,82	73,76
	Desvio	2,42	2,15	2,96	4,03	6,57
Tempo-Resposta	Mínimo	0	0	0	0	0
	Máximo	21	31	19	25	21
	Média	2,03	2,09	2,02	2,45	2,39
	Desvio	2,65	3,01	2,58	2,64	2,63
Acertos	Total	174	186	181	112	137
	Taxa	0,26	0,28	0,27	0,17	0,20

$\alpha$	$\beta$	$\theta$				
		0,5	0	1	2	4
Ociosidade	Mínimo	66,67	66,98	65,45	59,26	52,36
	Máximo	77,42	75,00	78,69	77,42	82,76
	Média	73,79	72,04	74,09	71,11	71,78
	Desvio	2,49	2,02	2,96	3,92	6,42
Tempo-Resposta	Mínimo	0	0	0	0	0
	Máximo	53	19	19	25	22
	Média	2,16	2,02	1,87	2,47	2,30
	Desvio	3,34	2,59	2,48	2,81	2,64
Acertos	Total	173	175	193	131	153
	Taxa	0,26	0,26	0,29	0,19	0,23

	$\alpha$ 0,75	$\beta$		$\theta$		
		0,25	0,5	0	1	2
Ociosidade	Mínimo	66,06	66,98	65,75	61,54	57,14
	Máximo	76,60	75,00	78,69	79,56	86,75
	Média	72,96	71,88	74,47	73,57	76,06
	Desvio	2,45	2,03	2,90	3,95	6,42
Tempo-Resposta	Mínimo	0	0	0	0	0
	Máximo	21	35	28	21	33
	Média	2,00	2,15	2,32	1,98	2,19
	Desvio	2,60	3,02	2,76	2,47	3,08
Acertos	Total	187	165	134	171	171
	Taxa	0,28	0,25	0,20	0,25	0,25

	$\alpha$ 1	$\beta$		$\theta$		
		0	0,5	0	1	2
Ociosidade	Mínimo	66,98	69,23	66,36	62,34	55,38
	Máximo	77,84	78,26	80,00	80,45	85,21
	Média	74,27	74,80	75,24	74,15	74,79
	Desvio	2,51	2,12	3,05	4,00	6,55
Tempo-Resposta	Mínimo	0	0	0	0	0
	Máximo	22	22	24	42	22
	Média	2,10	2,15	2,39	2,29	1,93
	Desvio	2,71	2,72	2,75	3,40	2,67
Acertos	Total	165	158	148	156	184
	Taxa	0,25	0,23	0,22	0,23	0,27