



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



MARCIO LUIZ DA COSTA LIMEIRA

**Proposta de Policiamento Inteligente: integrando modelos de localização
preditiva e de roteirização eficiente de patrulhas policiais**

Porto Alegre

2022

MARCIO LUIZ DA COSTA LIMEIRA

Proposta de Policiamento Inteligente: integrando modelos de localização preditiva e de roteirização eficiente de patrulhas policiais

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

Orientador: Prof. Dr. Luciano Ferreira

Porto Alegre

2022

CIP - Catalogação na Publicação

Limeira, Marcio Luiz da Costa
Proposta de Policiamento Inteligente: integrando
modelos de localização preditiva e de roteirização
eficiente de patrulhas policiais / Marcio Luiz da
Costa Limeira. -- 2022.
94 f.
Orientador: Luciano Ferreira.

Dissertação (Mestrado) -- Universidade Federal do
Rio Grande do Sul, Escola de Administração, Programa
de Pós-Graduação em Administração, Porto Alegre,
BR-RS, 2022.

1. Pesquisa Operacional. 2. Policiamento
Inteligente (Smat Policing). 3. Policiamento
Preditivo. 4. Segurança Pública. 5. Planejamento de
Patrulhas . I. Ferreira, Luciano, orient. II. Título.

MARCIO LUIZ DA COSTA LIMEIRA

Proposta de Policiamento Inteligente: integrando modelos de localização preditiva e de roteirização eficiente de patrulhas policiais

Dissertação aprovada para a obtenção do grau de Mestre em Administração pela Universidade Federal do Rio Grande do Sul – UFRGS, Escola de Administração, por:

Porto Alegre, 7 de julho de 2022.

Professor Doutor Luciano Ferreira - UFRGS

Professor Doutor Marcelo Bruttli Righi, Escola de Administração — UFRGS

Professor Doutor Pablo Cristini Guedes, Escola de Administração — UFRGS

Adiel Teixeira de Almeida Filho, Universidade Federal de Pernambuco - UFPE

Dedico este trabalho a minha mãe, Irma Irene (in memoriam), que semanas antes do início desse curso foi alegrar o céu. Exemplo de dedicação, de persistência, de alegria, de bondade, exemplo de vida, exemplo de amor, que nos guiou sempre em direção do melhor caminho.

A meu pai, Dalmar Luiz, que foi sempre um incentivador e torcedor de nosso sucesso.

A minha amada esposa, Luciane, pelo apoio, pela compreensão, pelo carinho na construção do trabalho e conclusão do curso, e sobretudo pelo amor e pela parceria nessa caminhada de quase 27 anos juntos.

A minha querida filha, Ana Laura, e meu querido filho, Tiago Luiz, fontes de inspiração na busca por uma sociedade melhor, onde impere o bem-estar e a paz social.

A meus irmãos Nemar Luiz, Luiz Fernando, Ana Lúcia e Fabio Luiz, que compartilharam das atividades que realizo, a policial militar e a de ensino, motivos de orgulho para mim.

Aos policiais militares da Brigada Militar, que diariamente se servem a sociedade gaúcha, desempenhando atividade fundamental, de grande complexidade, e cumprindo o compromisso de dedicação, mesmo com o risco da própria vida.

AGRADECIMENTOS

Agradeço, primeiramente, a Deus, Senhor de todas as coisas, Senhor da nossa vida, que nos iluminou a tentar apresentar soluções para melhor atendimento e segurança das pessoas.

A meus pais, pela educação e pelos ensinamentos de buscar a qualificação sempre, sendo incentivadores da busca do conhecimento, meus primeiros mestres de ética e moral, e de quem herdei o gosto pela matemática.

A minha esposa, Luciane, pela compreensão e apoio nos inúmeros momentos em que os códigos custavam a fechar, bem como no auxílio na revisão.

A meus filhos, Ana Laura e Tiago Luiz, pelo entendimento pelo tempo dispendido durante o curso, e pela motivação de concluir as atividades para compartilhar da vivência em que posso retornar a ser criança.

A meu orientador, professor Luciano Ferreira, pelo apoio e direção mesmo antes do curso, bem como pelo auxílio sempre pontual e fundamental, durante a produção desta dissertação, produção de artigos e demais atividades do curso.

Aos professores Dênis, Denise e Tiago, juntamente com o professor Luciano, por me auxiliarem na construção do conhecimento da pesquisa operacional, partindo quase do zero, possibilitando o entendimento teórico e capacitação prática na programação das atividades.

Ao colega e amigo, Marcos Maciel, parceiro de trabalhos, estudos e atividades, bem como na elaboração de trabalhos científicos apresentados durante o curso e já aplicados na Brigada Militar.

Aos colegas Andrey e Vilmar, pela companhia nessa caminhada durante o curso, mesmo diante das dificuldades da pandemia.

Aos amigos Roberto Donato, Moacir Simões e Marta, colegas que foram incentivadores desse trabalho contribuindo com sugestões e revisões.

Ao ex-secretário adjunto da segurança pública, Marcelo Frota, que incentivou e autorizou o desenvolvimento de pesquisas para desenvolvimento da gestão da segurança pública.

Ao Comando da Brigada Militar que autorizou as pesquisas e permitiu o emprego de algumas aplicações desenvolvidas durante o curso, que tem possibilitado a otimização da atividade de polícia ostensiva.

RESUMO

A presente dissertação apresenta proposta de policiamento inteligente a partir de um modelo integrado para o planejamento de ações policiais preventivas, considerando uma localização preditiva e uma roteirização eficiente de patrulhas. A segurança pública tem se apresentado como um problema cada vez mais complexo, que interfere diretamente na vida da sociedade, sendo que crimes violentos conduzem ao medo e a sensação de insegurança prejudicial ao convívio social e desenvolvimento das comunidades. Diante disso, busca-se propor um modelo para auxiliar no planejamento tático-operacional de patrulhas policiais com dois focos: posicioná-las em locais de maior risco de incidência de crimes de homicídios e sugerir rotas que permitam a cobertura dos pontos de risco com o menor tempo de deslocamento e, conseqüentemente, recursos. A proposta utiliza, para a localização das facilidades, a modelagem preditiva do *Risk Terrain Modeling* (RTM), empregando a ferramenta QGIS. Implementou-se a aplicação com dados reais para a prevenção de homicídios, a partir de fatores de risco específicos, de uma região do município de Porto Alegre, no período de 18 meses, entre janeiro de 2020 e junho de 2021. Após comparação com outros modelos de otimização como *k-means*, *p*-medianas e problema de localização com máxima cobertura (MCLP), o modelo RTM apresentou melhores resultados. Na sequência, o modelo integra uma proposta de roteirização, utilizando a metaheurística Busca Tabu, permitindo o atendimento dos pontos de risco, com grande aproveitamento do turno de serviço e redução de custos (distância e tempo) comparando-se com o emprego de uma heurística gulosa. Após os resultados, propõe-se um modelo integrado de policiamento inteligente, Modelo Preditivo de Localização e Roteirização de Patrulhas (MPLRP), o qual entende-se que pode ser utilizada na prática, tendo em vista que a verificação utilizou dados policiais reais e considerou as rotas nas vias públicas utilizando ferramenta Google Maps integrada em Python.

PALAVRAS-CHAVE: Policiamento Inteligente, Modelo Preditivo de Localização e Roteamento de Patrulhas, Risk Terrain Modeling, Busca Tabu.

ABSTRACT

The present thesis presents a proposal for smart policing based on an integrated model for planning preventive police action, considering predictive location and efficient patrol routing. Public security has become an increasingly complex problem which interferes directly in our society's life. Violent crimes lead to fear and to a feeling of insecurity that is detrimental to social coexistence and community development. Considering this, the goal is to propose a model to help with police patrol tactical and operational planning with two focal points: positioning patrols in locations with a higher risk of homicides and suggesting routes that enable the coverage of said areas with the lowest possible travel time, thus using less resources. The proposal uses the Risk Terrain Modeling (RTM) predictive model employing the QGIS tool to locate the premises. The application was implemented with real-time data to prevent homicides based on specific risk factors in a part of the city of Porto Alegre during an 18-month period, between January 2020 and June 2021. After comparing it with other optimization models such as k-means, p-medians, and maximum coverage location problem (MCLP), the RTM model obtained better results. Subsequently, the model became part of a routing proposal using the metaheuristic Tabu Search method, enabling the coverage of risk points with good use of the service shift and a reduction in costs (distance and time) compared to a greedy heuristic. After the results, an integrated smart policing model is proposed. The Predictive Model for Patrol Location and Routing (PMPLR) exhibits practical use possibilities, since the validation used real police data and considered routes on public streets by using the Google Maps tool integrated with Python.

KEYWORDS: Smart Policing, Predictive Model for Patrol Location and Routing, Risk Terrain Modeling, Tabu Search.

SUMÁRIO

1	INTRODUÇÃO.....	8
1.1	Problema	13
1.2	Objetivos	13
1.2.1	Objetivo Geral.....	13
1.2.2	Objetivos Específicos.....	13
2	REFERENCIAL TEÓRICO.....	15
2.1	Policimento Inteligente e Preditivo (Smart Policing /Predictive Policing).....	15
2.2	Risk Terrain Modeling (RTM).....	21
2.3	Problema de Localização de Facilidades	25
2.3.1	P-medianas	26
2.3.2	K-means	28
2.3.3	Problema de Localização de Máxima Cobertura (MCLP).....	30
2.4	Problema de Roteirização de Veículos (Vehicle Routing Problem – VRP) e de Roteirização de Patrulhas Policiais.....	33
2.4.1	Problema de Roteirização de Veículo com Janela de Tempo (Vehicle Routing Problem with Times Windows – VRPTW)	35
2.4.2	Heurísticas.....	36
2.4.3	Busca Tabu.....	38
2.5	Modelo integrado de alocação e roteirização de patrulhas policiais.....	40
3	METODOLOGIA	42
3.1	Definição e contextualização da Área de Estudo.....	42
3.2	Modelagem de Planejamento de Policiamento Inteligente	48
3.3	Modelo de Localização de Patrulhas	49
3.3.1	Modelo RTM.....	50
3.3.2	Modelo k-means.....	60
3.3.3	Modelo p-medianas	61
3.3.4	Modelo de problema de localização de máxima cobertura (MCLP)	64
3.4	Modelo de Roteirização de Viaturas	67
3.4.1	Parâmetros.....	69
3.4.2	Heurísticas utilizadas	70
4	RESULTADOS E ANÁLISE	71
5	CONSIDERAÇÕES FINAIS.....	84
	REFERÊNCIAS	87

1 INTRODUÇÃO

A questão da segurança pública tem afetado diretamente a vida da população, apresentando-se como um problema de natureza complexa, que demanda do Estado o investimento de recursos consideráveis para a garantia da paz social. A segurança pública tornou-se uma das principais preocupações das pessoas. Não havendo segurança, as pessoas alteram suas rotinas de trabalho e lazer, gerando medo e ansiedade. Quando as pessoas transferem parte da sua atenção, preocupadas em viabilizar suas atividades, visando à garantia de sua integridade física, elas prejudicam sua qualidade de vida e isso afeta o bem-estar geral da sociedade (GRABOSKY, 1995; BASÍLIO, PEREIRA, COSTA, 2020). Logo, a segurança pública mostra-se uma questão fundamental, a partir de uma percepção de bem-estar social da coletividade.

Destaca-se que a garantia da segurança pública surge como uma das primeiras funções do Estado Moderno, no que se refere à manutenção da ordem constitucional, tendo como objetivo concreto evitar a conturbação social por excelência: o acontecimento do crime (GUSSI, 2005). Nesse prisma, a preservação da ordem pública é a função essencial de um governo estatal, sendo que a sua legitimidade decorre de forma relevante quanto a capacidade de manter a ordem social (BAYLEY, 2002).

No entanto, a realidade, mormente nos grandes centros urbanos do país, é que o crime e o medo têm sido parte da rotina da população, apresentando-se de forma “onipresente e onipotente” na vida de cada um, a partir do “receio de ser vítima de um crime violento”, difundindo de maneira ampla o medo generalizado, gerando grandes custos sociais e impactos na qualidade de vida das pessoas, tais como as lesões e problemas psicológicos de saúde (MURRAY *et al*, 2013; AZEVEDO, CIPRIANI, 2015).

Como consequência, passa-se por um processo de aperfeiçoamento da gestão, especialmente, da administração pública, exigindo-se uma gestão mais eficiente, eficaz e efetiva, uma vez que diante do fato das ações prestacionais da administração pública serem custeadas pelos cidadãos-contribuintes, a população espera e exige qualidade nas ações de governo (CARVALHO, 1994, p. 139). Logo, a “escolha” os gestores públicos, em seu processo de tomada de decisão, deve ser a providência ótima, aquela que realize superiormente o interesse público, sendo competência administrativa: avaliar e escolher, no plano concreto, as melhores soluções (FREITAS, 2008; MELLO, 2009).

Neste cenário, na segurança pública, tem sido apontada a necessidade de aperfeiçoar o processo de gerenciamento dos órgãos de segurança, o desenvolvimento de tecnologias à

atividade policial, inovações nos processos de tomada de decisão e planejamentos, bem como uma maior integração com o público e a sociedade democrática (BEATO FILHO, 2009; BALLESTEROS, 2014). Assim, nota-se que o êxito das ações decorre, além do estabelecimento de um sistema de gestão estratégica, da execução de ações com uso de ferramentas para a correta tomada de decisão, impactando de forma direta para a redução dos crimes, sendo que algumas modificações nas atividades das polícias não decorrem de “macro soluções estruturais”, e sim de alterações “no estilo habitual de trabalho” dentro das instituições (BEATO FILHO, 2009).

Somando-se a necessidade de melhoria da segurança pública (resultado esperado), que pode ser alcançada através do tratamento transdisciplinar, gestão adequada e aperfeiçoamento do processo de tomada de decisão, encontra-se técnicas e métodos de pesquisa operacional, e policiamento inteligente (*Smart Policing*), como excelentes alternativas nesse processo.

A Pesquisa Operacional “é aplicada a problemas envolvendo como conduzir e coordenar as operações (isto é, as atividades) em uma organização” (HILLIER, LIEBERMAN, 2006). Ademais, “caracteriza-se pelo uso de técnicas e métodos científicos qualitativos por equipes interdisciplinares, no esforço de determinar a melhor utilização dos recursos limitados para programação otimizada das operações” de uma organização (ANDRADE, 2009).

Dessa forma, tem se dedicado a auxiliar a tomada de decisão, partindo do pressuposto de que as decisões, normalmente, são tomadas em circunstâncias “caracterizadas por objetivos conflitantes, condições variáveis, recursos limitados, dinâmica interpessoal complexa, incerteza e prazos inflexíveis” (JENSEN, BARD, 2003). A segurança pública, como já tratado, apresenta-se como uma questão na qual se pode identificar, facilmente, as características apresentadas.

No contexto das ações de polícia ostensiva (função constitucional atribuída às polícias militares, no Brasil, a fim de garantir a ordem pública através da ação de presença identificada), a atuação de policiais, nas modalidades de patrulhamento (atividades de deslocamento) e permanência (através da presença em locais definidos), utilizam, de forma genérica, basicamente de duas táticas para o controle do crime: a reativa (quando é chamada para o local onde ocorreu um fato delituoso com o objetivo de reestabelecer a condição de ordem social) e a preventiva (que decorre de atividades proativas dos policiais, para antecipar uma ação criminosa) (VANAGUNAS, 2007). Assim, o objetivo das ações preventivas é evitar a ocorrência de crimes, a partir da presença física de policiais.

Dessa forma, busca-se que os criminosos, a partir da percepção e de ações policiais evitem de delinquir, diante do efeito dissuasor da ostensividade policial (HUTT *et al*, 2018;

BRAGA *et al*, 2019; DEWINTER *et al*, 2020), sendo fundamental a alocação eficiente dos recursos existentes, para que os delitos possam ser evitados, através da localização das patrulhas nos pontos “propícios” ao acontecimento do delito (GURGEL *et al*, 2010; BRAGA *et al*, 2019; BASÍLIO, PEREIRA, 2020).

Nesse contexto, a utilização de métodos e modelos de otimização de alocação e roteirização de patrulhas policiais tem sido objeto de estudo por décadas (SIMPSON; HANCOCK, 2009; DEWINTER *et al*, 2020), a partir do desenvolvimento e aplicação de problemas clássicos como o Problema de Localização de Facilidades e Problema de Roteirização de Veículos.

Agrega-se, considerando, a disposição de recursos cada vez mais reduzidos, o desenvolvimento de medidas de análise preditiva no processo de tomada de decisão, para identificar possíveis locais de incidência criminal, com a finalidade de afinar o planejamento aos pontos de maior risco criminal, a partir da compilação de fatores indutores do crime.

Dessa forma, desde o início da década de 2010, tem se desenvolvido métodos de Policiamento Preditivo (*Predictive Policing*) e Policiamento Inteligente (*Smart Policing*), na busca por reduzir as ocorrências criminais. Essas propostas caracterizam-se por priorizar ações proativas com foco na antecipação, fundamentadas na utilização dos dados com análise aprimorada, com acompanhamento de desempenho e incentivo à inovação, para o emprego e desenvolvimento de estratégias e táticas adequadas de policiamento (COLDREN JR *et al*, 2013; PERRY *et al*, 2013; RUMMENS *et al*, 2017).

Embora as pesquisas na área estejam em crescimento, estudos sobre policiamento inteligente e preditivo ainda são relativamente escassos, sendo que pesquisas de revisão bibliográfica apontam que embora a aplicação de modelos de otimização na segurança pública, tenham surgido há décadas, os primeiros trabalhos com ênfase na predição remetem ao ano de 2010 (MEIJER, WESSELS, 2019; RATCLIFFE *et al*, 2019).

Com base nessa contextualização, o presente trabalho busca propor um modelo integrado de policiamento inteligente, para auxiliar no planejamento tático-operacional de patrulhas policiais com dois focos principais: alocação em pontos de maior risco de incidência de crimes de homicídios (de forma preditiva) e proposição de roteirização que possibilite a cobertura dos pontos de risco com o menor tempo de deslocamento e, conseqüentemente, recursos.

Assim, trata-se de uma pesquisa aplicada, utilizando como referência a área de ação de uma unidade operacional de Porto Alegre, que no ano de 2020 registrou o maior número de

ocorrências de homicídios no estado do Rio Grande do Sul. A implementação envolve duas fases: a localização preditiva de patrulhas policiais e a roteirização para cobertura dos pontos de maior risco com o menor custo de tempo.

Inicialmente, realiza-se a revisão dos temas de Policiamento Inteligente (Smart Policing) e Policiamento Preditivo (Predictive Policing), com ênfase no *Risk Terrain Modeling* (RTM), apresentada por Caplan, Kennedy e Miller (2011). Na sequência tratou-se da questão de localização de facilidades, detalhando os métodos do k-means, p-medianas e problema de localização de máxima cobertura (MCLP), que foram comparadas com a localização de pontos de risco a partir do RTM.

Após, descreveu-se os aspectos referentes ao problema de roteirização de veículos (patrulhas), delineando a variável do problema com janela de tempo (Vehicle Routing Problem with Times Windows – VRPTW). A revisão encerra com a apresentação das restritas pesquisas sobre modelos integrados de alocação de roteirização de viaturas policiais.

Seguindo para a metodologia, após a descrição da área e dos dados que se referem à aplicação do modelo, passou-se ao detalhamento das implementações.

Para a implementação do RTM utilizou-se a ferramenta QGIS, software livre e aberto de sistema de informação geográfica (GIS), que permite a elaboração de mapas integrando o gerenciamento e análise de dados, além de programação em linguagem Python.

O modelo buscou a definição de pontos de maior risco, a partir de unidades de espaço geográfico padronizados (grids), considerando diferentes camadas dos fatores de risco ao crime em estudo, *in casu*, os crimes de homicídios consumados ou tentados na área definida.

Destaca-se que a maioria das pesquisas que utilizam o RTM, exibem como resultado um mapa de risco para períodos longos como a previsão para um semestre ou ano subsequente, sendo que embora o método utilize parâmetros do ambiente, espera-se que com uma intervenção eficiente, os comportamentos e os riscos de uma determinada área seja alterada. Portanto, observou-se a possibilidade de testar o método para a realização de planejamento de previsão mensal, adaptando-se a possíveis alterações no ambiente e atuação criminosa, seguindo o parâmetro dos ciclos de acompanhamento de resultados definidos pelos órgãos de segurança pública do Rio Grande do Sul.

O método considerou como fatores de risco correlatos aos eventos de homicídios (segundo as referências pesquisadas): zonas de atuação de gangues e tráfico de drogas, locais de violência interpessoal e de conflitos violentos cotidianos; pontos de incidência de

homicídios, lugares de ocorrências de arma de fogo e áreas de vulnerabilidade (aglomerados subnormais, vilas e áreas de risco).

Ainda, foram considerados, nas escolhas dos parâmetros e fatores a alteração na dinâmica social ocorrida a partir de 2020, com a pandemia do COVID-19, o que se mostrou um aspecto limitador quanto a aplicação do RTM em sua essência, que considera, para a análise de risco, a existência de estabelecimentos e eventos de todos os segmentos. Tal limite, decorre das restrições de funcionamento de diversas atividades, total e parcial, determinados ao longo dos anos de 2020 e 2021. O que por si, apresenta-se como mais um desafio para o emprego da análise preditiva.

O modelo de alocação com base no RTM foi comparado com outros modelos de otimização: *k-means*, *p*-medianas e máxima cobertura. O modelo RTM apresentou melhores resultados, considerando o período de 18 meses, entre janeiro de 2020 e junho de 2021.

Na sequência, o modelo integra uma proposta de roteirização, considerando um problema de roteirização de veículos com janela de tempo (VRPTW), utilizando a metaheurística Busca Tabu, a partir de programação em Python, utilizando-se a biblioteca OR-Tools e integração com a ferramenta Google Maps, permitindo a utilização de dados reais de rotas, e utilizando-se heurística que permite a resolução eficiente do complexo problema de roteirização.

As rotas propostas permitem o atendimento dos pontos de risco, com grande aproveitamento do turno de serviço, e redução de custos (distância e tempo) comparando-se com o emprego de uma heurística gulosa. Além disso, testada com uma programação utilizando CPLEX, com limitador de tempo de 24 horas, uma vez tratar-se o VRPTW problema de complexidade *np-hard*, os melhores resultados viáveis nas instâncias geradas, no tempo definido, foram apenas 1% melhores que os gerados pelo Busca Tabu em poucos segundos.

Após apresentação dos resultados, propõe-se um modelo integrado de policiamento inteligente, Modelo Preditivo de Localização e Roteirização de Patrulhas (MPLRP), o qual entende-se que pode ser utilizada na prática, tendo em vista que a verificação utilizou dados policiais reais e considerou as rotas e distâncias utilizando as vias públicas urbanas.

Destarte, a apresentação dos resultados da aplicação do RTM mostra-se uma importante contribuição do trabalho, uma vez que compara um método preditivo de policiamento inteligente com modelos clássicos de otimização e localização de facilidades, no tocante a possibilidade de prever pontos com maior risco de incidência criminal. Tal questão mostra-se fundamental quando a alocação de patrulhas tem como fim precípua a prevenção pela

presença policial. Ademais, o modelo ainda não foi explorado no país, sendo pertinente a verificação de adaptação à realidade brasileira, no tocante ao caráter preditivo.

Referente ao modelo de roteirização, mostra-se a possibilidade de integração e utilização, através de aplicação utilizando metaheurística integrada com ferramenta o Gmaps, a possibilidade de emprego na atividade operacional, de acordo com os fundamentos da atividade de polícia ostensiva e da gestão pública, com maior eficiência e eficácia.

Enfim, o modelo integrado busca alcançar ao gestor do policiamento, a partir de dados criminais de período definido, considerando diversos fatores, identificar locais para a atuação preventiva (diante do risco de ocorrências de homicídios) e indicação de rotas para o cobrimento dos locais, reduzindo deslocamentos, apresentando-se como uma ferramenta indicativa ao auxílio do planejamento operacional.

1.1 Problema

Diante da necessidade de aprimoramento do planejamento das ações de policiamento preventivo em locais de risco, é possível aplicar um modelo integrado partindo da localização de pontos de policiamento considerando um modelo preditivo para a localização de patrulhas e implementando um modelo de roteamento eficiente?

1.2 Objetivos

Com mote no problema de pesquisa proposto a dissertação considera os seguintes objetivos:

1.2.1 Objetivo Geral

Propor modelo de policiamento inteligente integrado utilizando modelos de localização preditiva de patrulhas policiais e roteirização, a partir de uma abordagem heurística eficiente.

1.2.2 Objetivos Específicos

➤ Realizar revisão teórica de estudos sobre predição de crimes e policiamento inteligente, com vistas a difusão do tema no âmbito estadual e nacional, propondo modelo integrado para o planejamento operacional.

➤ Comparar a modelagem RTM com outros métodos de localização de facilidades, considerando o aspecto preditivo, para atuação policial.

➤ Verificar a possibilidade de emprego de método de análise preditivo para o crime de homicídio, de acordo com a realizada de área do município em estudo.

- Identificar e avaliar de fatores de risco, ocorrências correlatas e ambientais que envolvem o crime de homicídios em região de Porto Alegre.
- Propor a utilização, a partir da análise dos resultados, do RTM para previsão em curtos períodos (mensal).
- Avaliar a utilização de modelo de roteirização com a heurística Busca Tabu, para implementação na atividade policial, considerando pontos de maior risco de incidência de homicídios.
- Analisar a possibilidade de disposição de ferramenta integrada de predição e otimização nas atividades de policiamento preventivo.

2 REFERENCIAL TEÓRICO

2.1 Policiamento Inteligente e Preditivo (Smart Policing /Predictive Policing)

Com o aumento da criminalidade e do sentimento de insegurança das pessoas a complexa questão de segurança pública tornou-se uma das principais questões e pleitos da sociedade, conduzindo a necessidade do aperfeiçoamento das ações de prevenção e repressão aos crimes, a partir do estabelecimento de estratégias e táticas eficientes e efetivas.

Entre as ações para a garantia da segurança pública, a atividade de policiamento, através da presença ostensiva apresenta-se como o aspecto mais visível da reação da sociedade ao crime e a preservação da ordem pública, sendo uma a medida de controle social necessária para o bem-estar e convivência harmônica (CORDNER et al, 2007). Esse policiamento tem entre suas principais características a autorização coletiva social para o uso real da força, pelos agentes públicos que a exercem, quando alguém transgride as normas de convivência social, (BAYLEY, 2002).

Logo, os modelos tradicionais de policiamento buscam, através de ações preventivas e reativas, evitar que o crime ocorra ou reestabelecer o direito violado (integridade física e patrimônio), diante de uma agressão real ou iminente.

De tal modo, busca-se que os criminosos, a partir da presença policial, não cometam ilícitos (KOPER, 1995; HUTT et al, 2018; BRAGA et al, 2019; DEWINTER et al, 2020), sendo fundamental a alocação eficiente dos recursos existentes, para que os delitos possam ser evitados, através da presença policial no local “propício” ao acontecimento do fato criminal (GURGEL et al, 2010; BRAGA et al, 2019; BASÍLIO, PEREIRA, 2020).

Com esse objetivo, se faz necessário que os recursos sejam empregados nos locais onde possam evitar os fatos infracionais ou atender de forma mais rápida aos acontecimentos de emergência, sendo que a busca por soluções de otimização da alocação dos recursos policiais, seja na disposição de postos policiais ou viaturas, seja na definição de roteirização, têm sido objeto de estudo por décadas (SIMPSON; HANCOCK, 2009; DEWINTER et al, 2020), a partir do desenvolvimento e aplicação de problemas clássicos como o Problema de Localização de Facilidades e Problema de Roteamento de Veículos.

Agrega-se, considerando a disposição de recursos cada vez mais reduzidos, o desenvolvimento de medidas de análise preditiva no processo de tomada de decisão, para identificar possíveis locais de incidência criminal, agregando tal formato aos métodos e

modelos de otimização já estudados, a fim de estabelecer um planejamento de ações de forma mais eficiente e efetiva.

Nesse contexto tem se desenvolvido métodos de Policiamento Preditivo (Predictive Policing) e Policiamento Inteligente (Smart Policing) para estabelecer estratégias adequadas de policiamento com foco na redução dos índices criminais, priorizando ações proativas a partir da utilização eficaz dos dados, com o aprimoramento da análise, da medição de desempenho e incentivo à inovação (COLDREN JR et al, 2013). Tais métodos e estratégias têm como mote antecipar a atividade policial aos eventos criminosos, adotando ações preventivas, a partir do uso de ferramentas de análise (PERRY et al, 2013; RUMMENS et al, 2017).

Nesse sentido, diversos métodos de policiamento têm sido desenvolvidos, com fito de identificar, mormente, onde e quando ocorrerão os eventos criminais, para que a partir da alocação dos recursos limitados, nos locais de maior risco, esses “crimes previstos” possam ser evitados (PERRY et al, 2013; HART, ZANDBERGEN, 2014; MOSES; CHAN, 2018; YADAV et al, 2017; HUTT et al, 2018).

A possibilidade de “prever” ou “predizer” os crimes parte do reconhecimento de que os crimes não ocorrem de forma homogênea no espaço geográfico, mas, encontram-se concentrados em determinadas áreas e locais, conhecidas como hotspots, por razões que podem ser explicadas em relação à interação entre vítima e infrator, e as oportunidades que existem para cometer crimes (CHANEY et al, 2008; RATCLIFFE, 2010; JOHNSON, 2010; HART, ZANDBERGEN, 2014; RUMMENS et al, 2017; BRAGA et al, 2019). Tal enfoque, do estudo dos crimes com foco na análise de microunidades geográficas com maior concentração criminal, gerou na “a lei da concentração dos crimes”, a partir da escola da Criminologia do lugar, baseada em pesquisas que apuraram, em grandes cidades, a concentração de cerca de 50% dos fatos em aproximadamente 5% da área de estudo (WEISBURD, 2015).

Destarte, há evidências de que o crime é previsível, principalmente, porque os criminosos tendem a atuar em sua zona de conforto, em locais conhecidos, ou seja, eles tendem a cometer o tipo de crimes que realizaram com êxito anteriormente, geralmente em hora e local próximos aos das ações anteriores” (JOHNSON, 2010).

Logo, esses pontos críticos, tradicionalmente definidos como as regiões com taxas de crime mais altas (HUTT et al, 2018), em alguns casos possuindo pontos com ainda mais risco dentro desses hotspots (COLDREN JR et al, 2013), podem ser utilizados para decifrar os padrões espaciais do crime, para uma melhor compreensão teórica do papel da geografia e das

oportunidades, e conseqüentemente, possibilitar soluções práticas de prevenção do crime adaptadas a cada local (RATCLIFFE, 2010; JOHNSON, 2010).

A partir da percepção e identificação dos locais de concentração de crimes, estudos apontam que a realização de intervenções policiais focadas aos pontos críticos, como patrulhas dirigidas, prisões proativas e policiamento orientado para o problema, concentrando os recursos nas microunidades de maior risco (WEISBURD, 2015), pode produzir ganhos significativos na prevenção do crime, a partir de dois mecanismos teóricos fundamentais de prevenção do crime: dissuasão e redução das oportunidades de crime (BRAGA *et al*, 2019).

Entre os trabalhos sobre a eficácia das ações policiais Koper (1995) apresentou um estudo amplamente citado, no qual destaca que o patrulhamento intermitente com período de paradas em pontos de altos índices de criminalidade (segmentos de rua ou bairros). Segundo o estudo, analisando ações de polícia nas modalidades de patrulhamento (deslocamento da viatura) e permanência (paradas em pontos estratégicos). Ainda, a partir dos dados demonstra que após um período de parada, mesmo após a saída da viatura permanece um período de manutenção da ordem no local, com uma probabilidade reduzida de incidentes, por algum período.

Para tanto, demonstra que o tempo de parada deve ser de no mínimo 10 minutos, para que a presença policial tenha efeito dissuasivo residual, na área policiada, considerável, mostrando mais eficaz do que o simples patrulhamento pelos locais de risco. Por fim, analisando períodos de permanência de até 20 minutos, demonstra através da identificada como “curva de Koper” que a duração ideal de presença policial seria em torno de 15 minutos.

Logo conclui que "a polícia pode maximizar o crime e a desordem em pontos quentes, fazendo paradas proativas e de duração média nesses locais" (KOPER, 1995).

Nesse viés, as iniciativas de *Smart Policing* surgem nos Estados Unidos no ano de 2009, a partir de um período de diminuição de recursos materiais e pessoais para os órgãos policiais, oportunizando-se a busca pela identificação de soluções eficazes na redução dos índices criminais e eficientes com o melhor emprego de recursos, a fim de resolver para problemas criminais crônicos (COLDREN JR *et al*, 2013). Portanto, o *Smart Policing* representa uma progressão natural e necessária, na evolução da gestão policial, diante da atividade cada vez mais complexa e com recursos mais limitados.

Os autores destacam algumas características fundamentais das iniciativas de Policiamento Inteligente: aplicação de forma local (adaptada à realidade), foco na cientificidade e na pesquisa, abordagem multidimensional, orientado para resultados e esforço pela inovação.

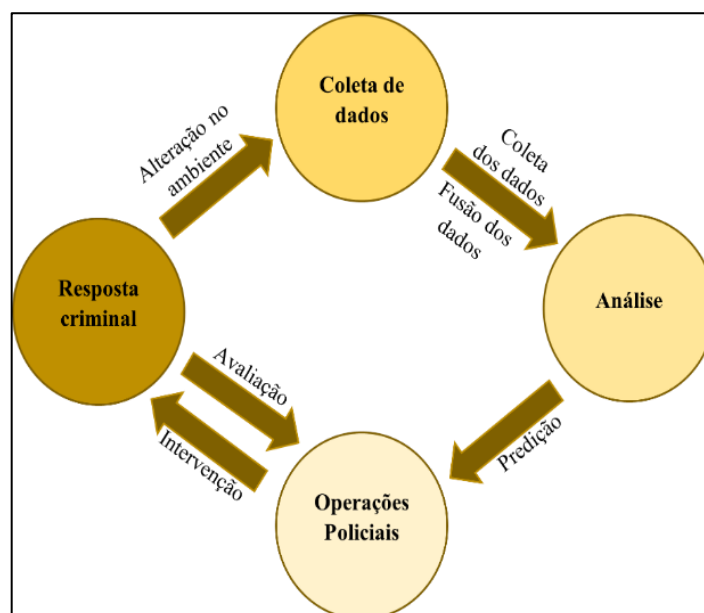
De forma complementar, o Policiamento Preditivo pode ser definido como a “aplicação de técnicas analíticas - principalmente técnicas quantitativas - para identificar alvos prováveis para intervenção policial e prevenir crimes ou resolver crimes passados através de previsões estatísticas ” (PERRY *et al*, 2011).

Ainda, caracteriza-se como um método que aplica técnicas quantitativas, a partir da coleta e análise de dados sobre crimes anteriores, para identificação e previsão em quais áreas geográficas tem maior probabilidade de atividade criminosa, para orientar o desenvolvimento de estratégias e táticas de intervenção e prevenção policiais (MEIJER, WESSELS, 2019). Ou seja, o objetivo do policiamento preditivo está em, a partir das técnicas e métodos analíticos, que sejam adotadas ações eficientes e efetivas, com o melhor emprego dos recursos e alcançando os resultados esperados, a redução dos índices criminais.

A partir das definições pode-se sintetizar que policiamento preditivo é um método do processo de tomada de decisão dos gestores de segurança pública, utilizando técnicas estatísticas e preditivas no planejamento das ações policiais proativas nos locais de maior risco, para alcançar maior eficiência (melhor emprego dos recursos), eficácia (atingindo os resultados esperados) e efetividade (gerando impacto no local de atuação).

Perry *et al* (2013) propõem um modelo de processo do policiamento preditivo, a partir de um sistema com quatro fases (Figura 1): coleta de dados, análise, operações policiais e resposta criminal.

Figura 1 - Processo do Policiamento Preditivo.



Fonte: PERRY *et al*, 2013

A etapa de coleta de dados é fundamental, uma vez que as técnicas de predição dependem de informações. Os bancos de dados da polícia, normalmente, contêm uma grande quantidade de dados criminais que podem ser usados para identificar sobre as tendências e padrões atuais e futuros do crime (RUMMENS *et al*, 2017; MEIJER, WESSELS, 2019).

Na fase de análise, os métodos e as técnicas são implementados não apenas para identificar os fatos ocorridos e o cenário existente, mas, para antecipar os próximos crimes. Portanto, a análise constitui a base para o emprego de recursos, sendo que, se os gestores e policiais não entendem os fatores que conduzem a um aumento da chance de crime, a eficácia de suas ações pode ser reduzida (PERRY *et al*, 2013; RUMMENS *et al*, 2017; MEIJER, WESSELS, 2019).

Seguindo, é preciso que o conhecimento gerado pela análise seja considerado no planejamento e execução das operações e ações policiais, para que de fato possam atingir os resultados, evitando o cometimento de crimes e proporcionando maior segurança à população envolvida com os pontos e situações de risco. Logo, a terceira fase do processo, é justamente a execução de operações/ações policiais, a partir da análise preditiva. Destaca-se que o policiamento preditivo apresenta grande conexão com o policiamento preventivo, sendo que os gestores da segurança pública devem trabalhar com vários atores na sociedade para reduzir e eliminar as oportunidades e os fatores que causam o comportamento criminoso (MEIJER, WESSELS, 2019).

A partir da intervenção policial, haverá a fase de observar a resposta criminal, a fim de identificar possível redução, deslocamento ou encerramento de crimes na área de atuação. Diante da resposta, haverá a avaliação, com ajustes necessários nas intervenções, de forma sistemática, até que ocorra a alteração no ambiente de atuação. Isso ensejará a coleta de dados, para nova análise e planejamento, formando um ciclo da gestão preditiva do policiamento (PERRY *et al*, 2013).

Os resultados do emprego de policiamento e ações com base em estratégias fundamentadas em análises preditivas, constataram reduções significativas nos índices criminais, demonstrando que “tais esforços têm, em média, um impacto geral redutor sobre o crime” (BOWERS *et al*, 2011; BRAGA *et al*, 2019; MEIJER, WESSELS, 2019).

Todavia, alguns estudos apresentam críticas quanto ao emprego de técnicas preditivas na segurança pública, apontando questões de falta de transparência dos modelos preditivos, no que se refere a eficácia e a responsabilidade desses modelos, além de levantar questões éticas de proteção da privacidade (MOSES; CHAN, 2018; MEIJER, WESSELS, 2019).

Agrega-se a isso a resistência dos operadores de segurança pública e a compreensão dos métodos e algoritmos preditivos, e implementação de inovações tecnológicas, não gerando o comprometimento necessário a execução e avaliação dos resultados ou como suas rotas de patrulha são configuradas, prejudicando a eficácia das previsões geoespaciais (RATCLIFFE *et al*, 2019; MEIJER, WESSELS, 2019).

As abordagens preditivas são diversas, conforme cada realidade e tipos de crimes, a partir de fundamentos teóricos e técnicas estatísticas complexas. Os primeiros estudos e aplicações partiram da identificação e mapeamento de pontos críticos de crime (*hotspots*), a partir de mapas de densidade com base na análise retrospectiva dos dados do crime, com o consequente direcionamento dos recursos policiais para esses locais, sendo reconhecida como uma técnica eficaz de combate ao crime (BRAGA, 2005).

Na esteira de desenvolvimento de ferramentas preditivas, Mohler *et al* (2011) desenvolveram o sistema PredPol, com base na aplicação de agrupamentos de fatos criminais no espaço e no tempo, relacionando com a afluência observada em eventos sísmicos, considerando que a partir de um terremoto, aumentam os riscos de eventos secundários, se poderia utilizar a percepção para a previsão de delitos.

Hart e Zandbergen (2014) apresentaram estudo comparativo quanto a definição de características na utilização de *kernel density estimation* (KDE) e *hotspots mapping*, tais como interpolação, tamanho das células e largura da banda, visando o aperfeiçoamento dos métodos utilizados. De outra banda, Rosser *et al* (2017) propõem a predição com base nos dados criminais históricos, considerando os segmentos de ruas como espaço geográfico, apresentando melhores resultados em comparação com os resultados de modelo de mapas de grade de risco.

Além disso, outras pesquisas apresentaram análise de previsão de crimes com base na influência de aspectos e de dados sociais: relacionando determinados fatores com a incidência criminal, com modelagem de clusterização (INGILEVICH, IVANOV, 2018).

Também, alguns estudos buscam a identificação dos pontos futuros de crimes, considerando aspectos ambientais, como Dash *et al* (2018) que realizou uma análise de rede com base em dados sociais e de estabelecimentos com relação a incidência criminal em Chicago, e Lin *et al* (2018) que utilizou informações do aplicativo *Google Places* para relacionar com locais de crimes identificando grids com maior risco em Taiwan.

Nesse sentido, ajustando um modelo com a ideia de identificar o risco ou potencial de crimes dos locais, considerando não somente dos dados anteriores do fato criminal a ser prevenido, mas também, informações dos ambientes para a partir da sua caracterização

(identificando fatores correlatos) possa se estabelecer o risco dos locais, Caplan *et al* (2011), já haviam desenvolvido o *Risk Terrain Modeling*, realizando a análise de risco a partir de camadas de mapas. Esse método será descrito mais detalhadamente, uma vez que será utilizado para compor a o modelo integrado proposto.

Do exposto, percebe-se que uma modelagem de policiamento inteligente, portanto, deve considerar a análise para identificação das características criminais no ambiente e no tempo, para antecipar o seu acontecimento, mas depende, fundamentalmente, do planejamento de ações policiais com base nessas informações, considerando a otimização dos recursos. Dessa forma, os métodos e modelos de predição devem agregar às pesquisas a identificação de pontos de maior risco e definição da forma de cobertura, através da maior permanência nesses locais.

A seguir, serão apresentados aspectos quanto à modelagem de risco terreno e à localização de viaturas policiais e do problema de roteirização de patrulhas, a fim de fundamentar o modelo de policiamento que será proposto.

2.2 Risk Terrain Modeling (RTM)

O *Risk Terrain Modeling* (RTM) trata-se de uma abordagem de análise de risco a partir da compilação, em um mapa composto, de camadas relacionadas com cada um dos aspectos de influência criminal correlato, verificando a sua influência e a sua intensidade para ocorrência de determinado crime. Utilizando um sistema de informações geográficas – GIS, esse modelo foi desenvolvido a partir da ideia de relacionar fatores que aumentam ou reduzem a probabilidade de crimes futuros em locais específicos, ou seja, fundamenta-se nos fatores de risco do lugar (CAPLAN *et al*, 2011; KENNEDY *et al*, 2011). Logo, é utilizada como ferramenta analítica que tem sido utilizada para identificar atributos do ambiente espacialmente associados à ocorrência de crime (VALASIK *et al*, 2019; STEINMAN *et al*, 2021).

Assim, em primeira análise, pode apresentar resultados qualitativamente semelhantes ao de um método de *hotspot*, destacando áreas com alto índice de criminalidade. Porém, analiticamente, são métodos muito diferentes, sendo que as análises de *hotspot* são técnicas de agrupamento que indicam os eventos criminais anteriores, enquanto no RTM há uma abordagem de classificação, que caracterizam o risco de crime de uma região com base em suas características geográficas (PERRY *et al*, 2013).

Ou seja, o diferencial do modelo consiste na relação do “risco de crime” com a “oportunidade para o crime”, a partir de uma avaliação de graus de risco de locais, considerando os fatores criminógenos, em relação a outros pontos com mesma unidade espacial padronizada.

O processo do RTM em três elementos principais: “1) padronização dos conjuntos de dados em uma geografia comum, 2) diagnóstico dos fatores de risco no espaço e 3) articulação das vulnerabilidades espaciais” (KENNEDY; DUGATO, 2018).

A modelagem do RTM inicia com a padronização dos conjuntos de dados em determinado espaço geográfico, como a extensão de uma cidade ou região, a qual será dividida em espaços padronizados (normalmente grades com lados de mesma dimensão). As dimensões das células de análise são variáveis, conforme cada estudo, considerando a extensão da área e o tipo criminal de interesse. Ressalta-se que trabalhos utilizando RTM têm sido aplicados no Estados Unidos, Itália, Colômbia, Canadá, Espanha, Áustria, Irlanda do Norte, Turquia e Japão (MARCHMENT; GILL, 2021).

Quanto ao período de análise e de predição, as pesquisas anteriores também apresentam uma variação, sendo que os criadores do método utilizaram períodos de análise de seis meses (CAPLAN *et al*, 2011) e três meses, para a predição de crimes para os mesmos períodos subsequentes. No entanto, em outros trabalhos o período utilizado tem sido a compilação de dados de fatores de período de um ano, para prever os eventos no ano seguinte (MORETO *et al*, 2014; DALEY *et al*, 2016; KENNEDY *et al*, 2016; PIZA *et al*, 2017; DUGATO *et al*, 2020).

Na sequência deve haver a seleção de fatores correlatos e a realização de diagnóstico da sua influência para o crime sob análise, considerando-se uma análise do fenômeno criminal na área determinada, para a partir da análise dos dados definir os fatores que serão empregados no RTM.

A flexibilidade do método, permite que sejam utilizados para a análise preditiva diversos fatores de risco, não somente dados criminais, mas também, de dados de localização de estabelecimentos, eventos, áreas de vulnerabilidade, entre outros aspectos, a partir da utilização em pesquisas anteriores ou segundo a experiência dos gestores da segurança pública, principalmente a partir da doutrina de criminologia ambiental. Assim sendo, a gama de fatores varia, conforme a realidade local e o tipo de crime estudado, além da disponibilidade de dados e informações.

Nesse ponto é que se inicia a abordagem técnica do RTM, a identificação preliminar dos fatores relacionados a um determinado crime para o qual o risco está sendo avaliado, como visto, pode ser realizada através de meta-análise, outros métodos empíricos, revisão de literatura, experiência profissional e conhecimento do profissional todos (CAPLAN *et al*, 2011).

Destaca-se que cada local ou área de análise tem um pano de fundo único (relação de ambiente e comportamentos), assim, a definição do agrupamento de certas características como condições para a ocorrência criminal não pode ser generalizada, ainda que diante do mesmo crime. Dessa forma, é necessário amoldar esses padrões dentro do contexto ambiental de cada região de estudo, para melhor compreensão da dinâmica espacial mais localizada do crime (BARNUM *et al*, 2017).

Após, sugere-se a realização de processo estatístico que identifica e pondera os fatores que se relacionam geograficamente aos incidentes do crime sob análise. Nesse sentido, algumas pesquisas testaram a relação entre os fatores de risco com os crimes definidos, através de regressão logística (KENNEDY *et al*, 2011), estatística qui-quadrado (CAPLAN *et al*, 2013) e regressão de Poisson e regressão binomial negativa (CAPLAN *et al*, 2015), e regressão de Poisson (DUGATO *et al*, 2020). A aplicação dos processos visa à identificação da significância dos fatores propostos, para definir o modelo de risco.

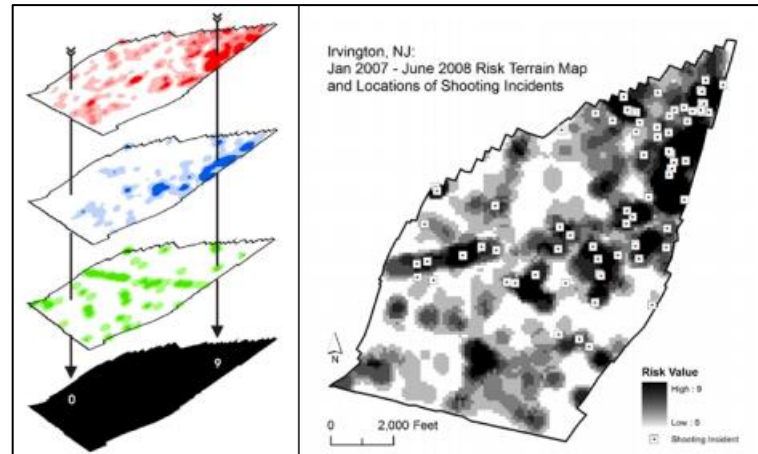
A partir da seleção dos fatores a serem utilizados, realiza-se a plotagem padronizada dos dados em um ambiente geográfico comum, exposto em uma camada do mapa contendo a área definida e as células de análise delimitadas, ou seja, cada fator é representado por um mapa de cobertura (raster) separado da mesma geografia (CAPLAN *et al*, 2011).

No modelo original de Caplan *et al* (2011), seguido por outras pesquisas, em cada camada de fatores independentes são atribuídos graus de risco para cada célula: grau = 0, para valores menores do que a média de incidência do fator; grau =1, para valores entre a média e mais 1 desvio padrão; grau=2, para os valores entre a média mais 1 desvio padrão e a média mais 2 desvios padrões; e grau=3, para valores superiores à média mais 2 desvios padrões.

Após a classificação das células do mapa, passa-se a fase de compilação das camadas dos diferentes fatores, para a produção do mapa de risco para identificação dos quadrantes com maior vulnerabilidade para a ocorrência do delito, realizando-se um processamento cartográfico em que as influências espaciais dos fatores ambientais selecionados são combinadas para comunicar informações sobre os contextos espaciais do crime.

Dessa forma, realiza-se a combinação das camadas de risco, produzindo um mapa composto, um mapa de risco do terreno, no qual a cada lugar (célula/grid), no mapa da área definida, é atribuído a um valor de risco que leva em conta todos os fatores associados ao resultado do crime específico.

Figura 2 - Representação de combinação de camadas de risco.



Fonte: (CAPLAN et al, 2011a).

Considerando as variações de implementações do método a compilação de risco de cada grid pode representar a soma dos valores de risco de cada camada ou utilizando a fórmula do valor de risco de cada célula (CAPLAN *et al*, 2015), no qual o cálculo do valor de risco local (VRL) é calculado utilizando os coeficientes de regressão como pesos:

$$VRL_g = \frac{\text{Exp}(\beta_0 + \sum_{f=1}^n x_{fg} \beta_f)}{\text{Exp}(\beta_0)}, \forall g \in (1, n), g \in \mathbb{Z} \text{ (Equação 1)}$$

Sendo:

VRL: Valor de Risco Local

x: valor de risco de cada fator

β : coeficiente de regressão

g: grid em análise

f: fator de risco

O mapa de risco combinado indica, portanto, as células/grids que apresentam maior risco terreno para a ocorrência do crime analisado, servindo, no modelo ora apresentado, como orientação para o planejamento tático-operacional no tocante ao emprego dos recursos policiais e para desenvolvimento de operações e ações, que possam diminuir o risco local, a partir da dissuasão gerada pela presença policial ou outras ações estruturais que alterem o ambiente de risco. Ou seja, a análise de previsão do RTM apresenta-se como ferramenta para a adoção de ações do modelo de policiamento preditivo, conforme conceitos apresentados.

Quanto a eficácia do método, no aspecto preditivo, pesquisas têm justificado os benefícios em comparação com o policiamento em hotspots, KDE e outros métodos de análise

preditiva, conforme sistematizado em pesquisa de revisão sistemática e meta-análise da literatura, constatando que o RTM tem sido bem-sucedido na identificação de locais de risco (MARCHMENT; GILL, 2021).

Ademais, considerando os critérios de avaliação do método observou-se diferentes resultados, diante do emprego em diferentes regiões, crimes, fatores de risco e parâmetros apresentou bons resultados conforme os índices. Sendo que, a partir da meta-análise realizada nos estudos sobre o RTM, identificaram uma precisão de cerca de 44,7% de eventos ocorridos em 10% das células avaliadas, classificadas como de alto risco (MARCHMENT; GILL, 2021).

Dessa forma, os locais classificados como de alto risco podem ser utilizados para a localização de recursos policiais, especialmente, para ações de prevenção de crimes, uma vez que os locais indicam possíveis locais de incidência do evento.

2.3 Problema de Localização de Facilidades

A localização de facilidades apresenta-se como um dos problemas clássicos da Pesquisa Operacional, sendo que tem como objetivo otimizar os recursos, distribuindo-os no espaço para atender a demanda existente de forma a melhor atender os clientes.

De maneira geral, o problema de localização consiste em minimizar os custos (distância ou tempo) da facilidade até a demanda ou dos usuários até a facilidade, apresentando importância prática na localização de ambulâncias em áreas urbanas, localização de antenas de comunicações, localização de centros de distribuição e de pontos base para viaturas policiais (GURGEL *et al*, 2010). Quanto na área pública, na qual a localização de facilidades de educação, saúde e segurança, entre outras áreas, relaciona-se com a qualidade dos serviços prestados (KLOSE; DREXL, 2005).

No que se refere a utilização de modelos de localização de facilidades na segurança pública, pode se verificar no trabalho de Simpson e Hancock (2009), que trata de cinquenta anos da pesquisa operacional e serviços de resposta de emergência, foram analisados 361 artigos, dos quais diversos relacionam-se a respostas de órgãos de segurança pública.

Logo, considerando as atividades principais da polícia ostensiva, prevenir o crime e minimizar o tempo de resposta para o atendimento de ocorrências, o posicionamento otimizado dos recursos no terreno mostram-se fundamentais, sendo que as patrulhas devem estar onde há maior possibilidade de incidência criminal (evitando o crime com a ação de presença) ou mais próximo possível dos locais de maior quantidade de registros e chamadas de urgência (atendendo as chamadas de emergência o mais breve possível), como já tratado.

Segundo Klose e Drexl (2005) os modelos para problemas de localização partem da teoria de localização de indústrias de Weber de 1909, na qual a determinação do ponto de instalação de uma planta industrial consideraria a menor distância entre a soma das distâncias dos locais de origem da matéria prima e de destinação do produto, a partir da qual foram desenvolvidas diversas modelagens.

Nesse sentido, um modelo genérico de localização, envolve os locais possíveis de instalação do recurso e os pontos de demanda podem ser dispostos em um grafo, a partir da ideia de uma rede, na qual os nós representam pontos de demanda, os locais de instalações potenciais correspondem a um subconjunto de nós e as ligações entre os possíveis pontos de posicionamento e os pontos de demandas formam os arcos do grafo (KLOSE; DREXL, 2005).

2.3.1 P-medianas

Um dos métodos desenvolvidos e utilizados é o modelo de p-medianas, um modelo clássico de localização de facilidades, que tem como objetivo encontrar a localização de p centros (medianas) localizados em uma rede, no qual as instalações p devem ser localizadas em um grafo de forma que a soma das distâncias entre os nós do grafo (demandas) e a instalação mais próxima seja minimizada. Ao final, as p-medianas definidas na solução do modelo representarão os locais das p facilidades que serão distribuídas no espaço delimitado (GURGEL *et al*, 2010; SILVA *et al*, 2013).

O modelo de p-medianas ampliou-se considerando o estudo de Hakimi (1964), que tratou da utilização de locais potenciais entre os nós existentes no conjunto de vértices do grafo, nos casos em que a facilidade deveria chegar até a demanda (sinal de comunicações), apresentando o teorema de que: “uma mediana absoluta de um grafo está sempre em um vértice de um grafo” (HAKIMI, 1964). Inclusive, descreve como um exemplo aplicável a localização de um posto policial do qual uma viatura deveria deslocar para os locais de acidentes, caso pertinente ao objeto de estudo. Assim, um ponto ideal para a localização de um recurso policial para atender demandas de ocorrências, estaria no próprio grafo determinado pelas demandas de eventos.

A fórmula das p-medianas, como método de solução para a localização de facilidades, pode ser apresentada como:

$$f(x) = \text{Min} \sum_{i=1}^n \sum_{j=1}^n c_{ij} x_{ij} \quad (\text{Equação 2})$$

Sujeito a:

$$\sum_{j \in D}^n x_{ij} = 1, \forall i \in L \quad (\text{Equação 3})$$

$$\sum_{i=0}^n y_i = p, \forall i \in L \quad (\text{Equação 4})$$

$$x_{ij} \leq y_i, \forall i \in L, \forall j \in D \quad (\text{Equação 5})$$

$$x_{ij}, y_i \in \{0, 1\}, \forall i \in L, \forall j \in D \quad (\text{Equação 6})$$

Sendo x_{ij} a aresta entre uma localização de facilidade i (mediana) e o ponto de demanda j , tratando-se de uma variável binária sendo 1 se a aresta se encontra na solução e 0 no caso contrário; e c_{ij} o custo entre os pontos. Portanto, a função objetivo (Equação 2) é minimizar a soma dos custos com as arestas da solução, considerando a quantidade p de facilidades definida.

A primeira restrição (Equação 3) estabelece que todos os pontos de demanda serão relacionados a uma facilidade. Além disso, diante de outra variável binária y (sendo 1 se o local é parte da solução, e 0 caso contrário), sendo que a soma dessas variáveis deve ser igual ao número de medianas definidas (Equação 4). Assim, fica garantido que serão escolhidos p locais de facilidades. Ainda, há necessidade de vincular cada um dos locais de ocorrências correlatas com um local candidato (Equação 5).

Quanto a aplicação do modelo na segurança pública, Gurgel *et al* (2010), apresentando um modelo híbrido para a alocação de unidades policiais e roteirização, utilizou p -medianas para definir a localização de novas unidades policiais no município de Natal, a partir da identificação de pontos com maior incidência de ocorrências, num período de nove meses, considerando como peso a quantidade de incidentes criminais. Dessa forma, a alocação de unidades estava próxima a locais com grande taxa de criminalidade, diminuindo o tempo de chegada para atendimento policial.

Silva *et al* (2013), para definição de locais candidatos para posicionamento de viaturas policiais em Recife, utilizou três métodos: problema de p -medianas, técnica de clusterização k -means e critérios adotados pelo gestor. No que tange a aplicação de p -medianas utilizou os locais de eventos de homicídios para definir os nós dos grafos, e a partir dele identificar as medianas que melhor atenderiam os pontos de “risco”.

De forma semelhante, as p -medianas foram utilizadas para estabelecer a localização de bases policiais em Londres, com vistas a redução de custos operacionais e maior segurança, agregando a ideia de máxima cobertura (CHOW *et al*, 2015). Ainda, o modelo de p -medianas foi utilizado para, além da definição da localização das unidades policiais, definir as áreas de

responsabilidade de cada uma delas, considerando, a partir dos dados de chamadas de serviço, o tempo gasto com os deslocamentos, mas também buscando equalizar os atendimentos pelos patrulheiros de diferentes áreas (WHEELER, 2018).

Nota-se que a formulação de localização de facilidades como p-mediana tem como mote estar o mais próximo possível dos pontos de demanda, podendo inclusive estar entre esse conjunto (um dos vértices do grafo), mas indicando pontos que reduzirão os custos de deslocamento. Portanto, considerando as questões já tratadas, está voltada a ações reativas, por exemplo: posicionar uma viatura para estar mais próximo dos possíveis locais de ocorrência, assim busca-se reduzir o tempo de resposta (tempo de chegada da facilidade até a demanda).

2.3.2 K-means

O método de clusterização k-means é um algoritmo de aprendizado de máquinas não supervisionado, ou seja, não necessita prévia classificação e parametrização, para clusterização (SINCLAIR, DAS, 2021). Como uma técnica de clusterização, busca o agrupamento em k classes, a partir de uma medida de similaridade, agrupando elementos com grande semelhança, buscando encontrar padrões (JAIN, 2010). Com este objetivo, os procedimentos de agrupamento tendem a encontrar um conjunto de k pontos para atuar como centros (centroides) e, na sequência, atribuindo cada elemento dos dados ao seu centroide mais próximo, formando-se os clusters (GUSMÃO *et al*, 2020).

Conforme Jain (2010), o algoritmo k-means “tem uma história rica e diversificada, pois foi descoberta independentemente em campos científicos diferentes por Steinhaus (1956), Lloyd (proposto em 1957, publicado em 1982), Ball and Hall (1965) e MacQueen (1967)”. Assim, destaca que, embora o grande lapso temporal desde o início de sua aplicação, é um dos algoritmos mais utilizados para clusterização de dados, em virtude da “simplicidade, eficiência e sucesso empírico”, (JAIN, 2010; OLIVEIRA, 2012; GUSMÃO *et al*, 2020; SINCLAIR, DAS, 2021).

Destaca-se que o algoritmo k-means requer três parâmetros definidos por quem o implementa: número de clusters k , inicialização de cluster e métrica de distância (JAIN, 2010). Quanto aos pontos de inicialização, convém apontar que diferentes inicializações podem levar a agrupamentos finais difusos, pois o k-means tende a convergir para um mínimo local.

Fundamentalmente, o k-means busca encontrar os clusters minimizando a soma das distâncias entre os pontos dos dados ao centroide mais próximo (OLIVEIRA, 2012). Dessa

forma, a função objetivo de modo bem simplificada pode ser apresentada, conforme Gusmão et al (2020):

$$f(x) = \text{Min} \sum_{k=1}^k \sum_{x_i \in C_k} d(x_i, x_{0k}) \quad (\text{Equação 7})$$

Onde:

- x_{0k} : é o centroide do cluster x_{C_k} ; e
- $d(x_i, x_{0k})$: é a distância entre o ponto x_i (pontos que pertencem ao cluster) e ponto x_{0k} (centroide).

Destaca-se que minimizar essa função objetivo apresenta-se como um problema np-hard (JAIN, 2010). Todavia, o k-means utiliza um algoritmo guloso com boa escalabilidade, podendo agrupar um conjunto de dados de moderadas a altas dimensões, com custos computacionais reduzidos (SINCLAIR, DAS, 2021)

O algoritmo compreende três etapas (ZHU *et al*, 2019):

- Etapa 1 – são definidos ou selecionados aleatoriamente k centroides dentro do conjunto de dados original.
- Etapa 2 – calcula-se a distância entre cada ponto da base de dados e cada centroide, vinculando o ponto ao centroide mais próximo. Portanto, o k-means é tipicamente usado com a métrica euclidiana a partir das distâncias entre pontos e centros de cluster.
- Etapa 3 – Atualiza-se os centroides, no centro dos cluster, formados pelos pontos vinculados ao mesmo centroide.
- Repete-se as etapas 2 e 3 até que o centroide permaneça o mesmo e saia do looping.

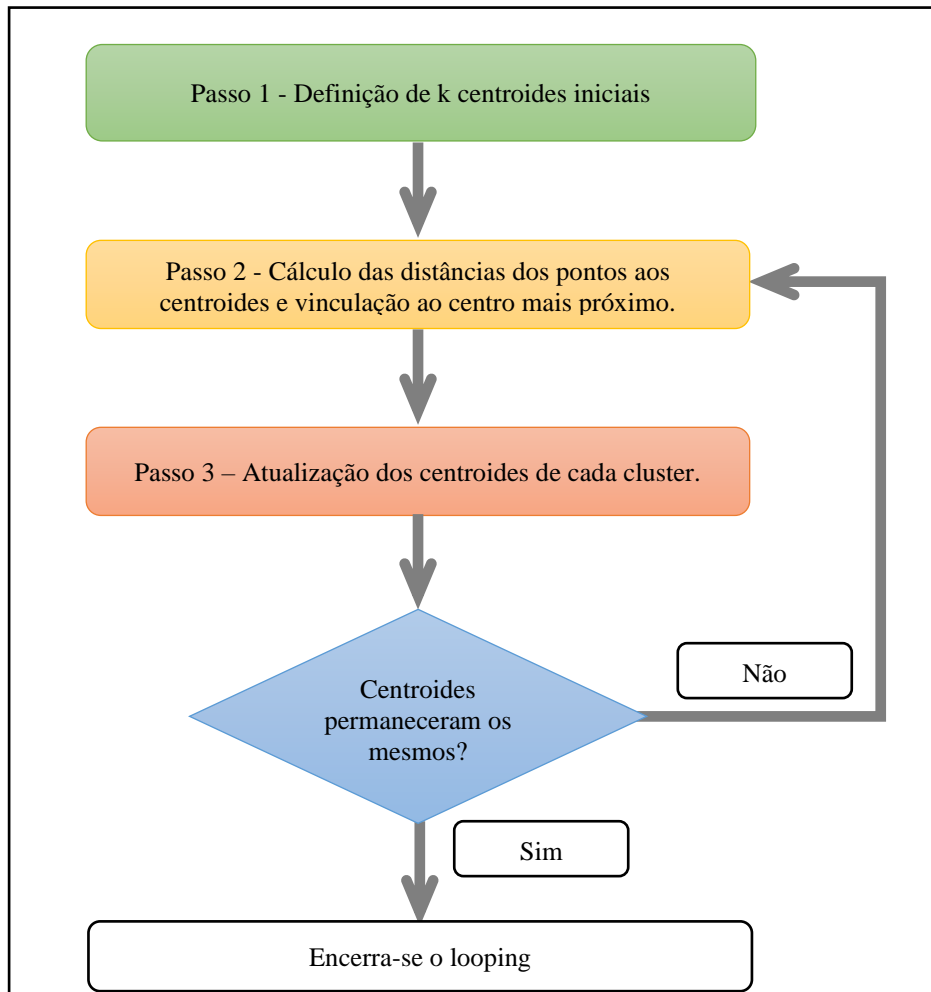
Gusmão *et al* (2020) destacam que o método pode ser aplicado a problemas de localização de facilidades, uma vez que pode ser sintetizado ao localizar os k centroides, definindo assim as possíveis locais candidatos para posicioná-las.

Além disso, Zhu *et al* (2019) utilizam o k-means para análise criminal, propondo um modelo preditivo, a partir de características dos crimes, a fim de prever a quantidade de ocorrências em determinado micro local.

Sinclair e Das (2021) utilizaram o algoritmo de clusterização para identificar padrões de acidentes rodoviários no Reino Unido e entender as relações entre as variáveis registradas pelo departamento de polícia.

No Brasil, alguns trabalhos têm incluído o método para localização de locais candidatos para patrulhas e postos policiais, considerando estar em um ponto central das demandas, com fundamento em base de dados criminais (OLIVEIRA, 2012; SILVA *et al*, 2013; GUSMÃO *et al*, 2020).

Figura 3 - Etapas do algoritmo k-means



Fonte: elaborado pelo autor

2.3.3 Problema de Localização de Máxima Cobertura (MCLP)

O problema de localização de máxima cobertura (Maximal Coverage Location Problem - MCLP) foi desenvolvido por Church e Reville (1974), justamente na busca de um modelo que melhor atendesse a localização de serviços públicos, considerando as duas possibilidades de aplicação de métodos de otimização de localização de serviços de atendimento ao interesse público: a distância e o tempo de deslocamento da facilidade até os usuários, e a distância ou tempo de deslocamento do usuário até a facilidade (CHURCH, REVELLE, 1974).

A ideia central compreende maximizar a cobertura da demanda, considerando um padrão de serviço (distância ou tempo máximo de deslocamento esperado, por exemplo), localizando um número fixo de instalações.

Dessa forma, considerando recursos limitados, as facilidades seriam localizadas de forma que seriam atendidos, o máximo da população, dentro do parâmetro aceitável ou necessário para a prestação de serviço. Por exemplo, considerando serviços de emergência, no qual há um tempo padrão aceitável para chegada, por exemplo na atividade de pronto atendimento ou serviços de bombeiros.

Com base na formulação apresentada por Church e Reville (1974), apresenta-se o seguinte modelo matemático do MCLP:

$$f(x) = \text{Max} \sum_{i \in D} x_i \quad (\text{Equação 8})$$

Sujeito a:

$$\sum_{j \in N_i} y_j \geq x_i, \forall i \in D \quad (\text{Equação 9})$$

$$\sum_{j \in C} y_j = p \quad (\text{Equação 10})$$

$$x_i, y_j \in \{0, 1\}, \forall i \in D, \forall j \in C \quad (\text{Equação 11})$$

Sendo:

- D = o conjunto de nodos de demanda;
- C = o conjunto de locais de facilidades;
- S = distância máxima de cobertura
- d_{ij} = distância entre o nodo i e a facilidade j ;
- $y_j = 1$, se a facilidade é alocada no local j ; 0 caso o contrário;
- $N_i = \{j \in C \mid d_{ij} \leq S\}$;
- p = o número de facilidades que serão alocadas.

Assim, a função visa a maximizar o número de pontos atendidos pelas facilidades dentro do limite de distância/tempo de cobertura definido (Equação 8). Inicialmente, propõe-se a restrição (Equação 9) de que a variável x_i seja igual a 1, apenas quando uma ou mais facilidades estão localizadas dentro de da distância S máxima estabelecida do ponto i . Ainda, define-se que o número de facilidades alocadas é restrito a quantidade de p (Equação 10). Por

fim, apresenta-se a restrição de limites das variáveis (Equação 11), no caso inteiras e binárias (CHURCH, REVELLE, 1974).

Como tratado por Murray, as aplicações desse modelo são inúmeras e as pesquisas permitem a evolução de resolução e aplicações do método (MURRAY, 2016), apresentando resultados práticos importantes na localização de facilidades e atendimento de demandas.

Karatas *et al* (2016) e Murray (2016) descrevem que o MCLP tem sido utilizado na localização de facilidades como alocação de instituições e agências de segurança, armazéns, sistemas de emergência e instalações de saúde, localização de sensores de vídeo para controlar a segurança de uma área urbana, posicionamento e despacho de ambulâncias, localização de estações de bombeiros e postos policiais.

O MCLP já foi aplicado para otimizar a cobertura de policiais em áreas de interesse da segurança (com maiores incidências), a partir da distribuição de policiais em uma determinada área, com a finalidade de realizarem o patrulhamento e monitoramento nas áreas da cidade com maior índice de criminalidade ou outra característica de interesse específico que precisem ser priorizadas (CALDERIN *et al*, 2017).

Também, Gusmão *et al* (2019) aplicaram o MCLP em um sistema de informação de gestão, para apresentação de proposta de alocação de viaturas em Pernambuco, a partir de dados de criminais.

No trabalho de Karatas *et al* (2016) apresenta-se uma comparação entre a p-mediana e o MCLP quanto a seus desempenhos em relação a cinco critérios de decisão: distância média do primeiro recurso, distância média para o primeiro recurso e recurso de backup, distância média para o recurso de backup, proporção de demanda com cobertura de recurso primário e de backup no intervalo de tempo estabelecido, e proporção de demanda com cobertura de recurso primário no limite de intervalo estabelecido. No geral, o modelo p-mediana mostrou melhores resultados em quatro dos cinco critérios, em comparação ao MCLP.

Finalmente, considerando as proposições para alocação de recursos, destaca-se que o posicionamento de recursos policiais de forma proativa deve buscar definir pontos com maior risco de ocorrência, a fim de que com a presença policial possam ser evitados, como tratado nas medidas de policiamento preditivo e policiamento inteligente. Assim, o estudo realizará uma comparação dos resultados, no que se refere a avaliação preditiva, dos pontos definidos por cada método.

2.4 Problema de Roteirização de Veículos (Vehicle Routing Problem – VRP) e de Roteirização de Patrulhas Policiais

O Problema de Roteirização de Veículos (*Vehicle Routing Problem – VRP*) trata-se de um dos principais problemas de otimização combinatória, e foi apresentado originalmente por Dantzig e Ramser em 1959, através do *paper* “*The Truck Dispatching Problem*”, tratando-se uma generalização do Problema do Caixeiro Viajante (*Traveling Salesman Problem – TSP*). Sinteticamente, buscava implementar uma solução para o problema de caminhões, com determinada capacidade, saindo todos de um terminal, os quais deveriam realizar entregas aos clientes (cada qual com sua demanda), minimizando a distância total percorrida pelos caminhões necessários ao atendimento da demanda (DANTZIG, RAMSER, 1959).

Genericamente, o VRP compreende, portanto, a definição do conjunto de rotas ótimas, com menor custo (tempo ou distância) total, para determinada frota de veículos; partindo de um depósito (ao qual deverá retornar ao final da rota); para atender a um conjunto determinado de clientes ou de pontos de demandas (que devem ser visitados exatamente uma vez); e considerando suas restrições peculiares como capacidade de entrega e/ou tempo e distância máximos atendidos por uma rota (LAPORTE, 1992; LAPORTE, 2007; SHARMA *et al*, 2018).

Assim, o problema compreende um grafo $G = (V, A)$, sendo:

- V o conjunto de vértices: $V = \{0, 1, \dots, n\}$;
- A o conjunto de arcos: $A = \{(i, j) : i, j \in V, i \neq j\}$;
- v_0 o depósito de onde partem m veículos para o cumprimento das rotas, para atender as demandas de cada cliente.


Portanto, trata-se de questão diretamente relacionada ao cotidiano com diversas aplicações na área de logística, prestação de serviços, atendimentos de emergência e serviços de segurança, entre tantas outras aplicações.

Note-se que a definição de rotas para as patrulhas policiais enquadra-se nesse problema clássico:

- as viaturas (veículos) iniciam e encerram o serviço na sede policial.
- devem deslocar a pontos definidos, realizando a cobertura dos locais planejados, para posicionar-se para uma melhor pronta-resposta ou prevenção em locais de risco ou de interesse.

- a capacidade de atendimento dos pontos e o tempo para o cumprimento da rota, considerando o tempo de permanência nos locais visitados, não devem exceder aos limites definidos para o serviço.
- quanto menor o tempo de deslocamentos, menor os custos com necessidade de recursos, além de possibilitar um maior tempo de permanência nos pontos de risco.

Figura 4 - Representação de rotas de viaturas de polícia



Fonte: elaborado pelo autor

Destarte, o estudo e aplicação do VRP, para o planejamento dos percursos de viaturas de policiamento, tem crescido com a necessidade de otimização dos recursos, mostrando-se, notadamente, como uma medida importante para enfrentamento da criminalidade, com foco na resposta aos chamados e na prevenção de ilícitos (YASSEN *et al*, 2017). Assim, essa especificação do VRP, tem sido definido, em alguns trabalhos, como o Problema de Roteirização de Patrulhas Policiais (*Police Patrol Routing Problem – PPRP*). Destaca-se que trabalhos utilizando essa designação, embora em quantidade reduzida, apresentam uma variedade de modelos para a solução do PPRP.

O trabalho já citado de Gurgel *et al* (2010), trata da alocação de unidades policiais e de um modelo de roteirização de unidades policiais. Assim, no que se refere ao modelo de roteirização, aplica uma alocação dos pontos de ocorrências a unidade policial mais próxima, e após define uma rota para cada órgão policial, considerando a formulação do TSP.

Outras abordagens tratam da determinação de rotas de patrulhamento a partir de um modelo integrado denominado Problema Roteirização de Patrulha com Máxima Cobertura (*Maximum Coverage Patrol Routing Problem – MCPRP*), considerando *hotspots* com janelas de tempo, no qual busca maximizar a permanência nos pontos de risco, agregando conceitos do Problema do Caixeiro-Viajante Seletivo (quando não há possibilidade de atender todos os

clientes) e do Problema de Orientação, apresentando solução através da Heurística da Busca Tabu (KESKIN *et al*, 2012).

Considerando o Problema de Tour de Cobertura de Multi-Veículos (Multi-Vehicle Coveraging Tour Problem - *m-CTP*), Oliveira *et al* (2015) construíram um modelo de roteirização para o patrulhamento policial, buscando minimizar as distâncias com atendimento das demandas, comparando a aplicação de heurísticas: *Greedy Selection*, *Sweep Routine*, *Route-first/Cluster-second*, e *Sector Partition*.

Yassen *et al* (2017) também consideram a janela de tempo nos pontos quentes para considerar o PPRP como uma generalização do Problema de Roteirização de Veículos com Janela de Tempo (*Vehicle Routing Problem with Times Windows – VRPTW*), definindo que as atividades das patrulhas seriam divididas em missões, sendo que cada missão seria composta por um conjunto de rotas que atenderiam determinada quantidade de pontos de atendimento, sendo que a distribuição de missões consideraria a maximização do atendimento dos “graus de risco das rotas”, a partir dos pontos atendidos, sendo resolvido através de uma heurística construtiva.

Com foco na redução do tempo resposta, Dewinter *et al* (2020) realizaram a revisão de 30 artigos, do que chamaram do Problema de Roteirização de Patrulhas Policiais (*Police Patrol Routing Problem - PPRP*), avaliando as pesquisas relacionadas ao problema de roteirização dinâmica (*Dynamic Vehicle Routing Problem - DVRP*), concluindo a possibilidade de ampliação de pesquisas para ações proativas, considerando possibilidades preditivas e preventivas, além de analisar métodos determinísticos, que podem ser úteis para o desenvolvimento da temática.

Ainda, antes de destacar as variações do VRP e PPRP que serão aplicadas no presente trabalho, cumpre tratar da complexidade do problema do VRP e suas variações, que serão aplicadas. Quanto a esse aspecto, o VRP e suas variantes são problemas np-hard, como já demonstrado (LENSTRA e RINOOY KAN, 1981), logo, a maior parte dos métodos indicados para resolvê-los são fundamentados em heurísticas, existindo várias opções apresentadas na bibliografia (LAPORTE, 2007).

2.4.1 Problema de Roteirização de Veículo com Janela de Tempo (Vehicle Routing Problem Time Windows – VRPTW)

Essa variante do problema de roteirização de veículos agrega restrições de intervalo de tempo associado aos pontos de atendimento (demanda ou de coleta) descrita como a “janela de tempo” para cumprimento da visita/atendimento, decorrente da disponibilidade de receber o

serviço da rota somente em determinado período. Assim, às características gerais do VRP associa-se: uma janela de tempo, compreendendo os limites inferiores e superiores para atendimento em cada ponto; e um tempo de serviço para permanência em cada ponto (para cumprimento da atividade) (TAILLARD *et al*, 1997).

Observa-se que o modelo se adequa a atividade de patrulhamento, sendo que as rotas devem atender o tempo máximo do turno das patrulhas e podem considerar a janela de tempo para visitas de pontos de interesse, por exemplo considerando o período de funcionamento de um estabelecimento a ser policiado (por exemplo: escola, banco, comércio) ou período de risco em determinado local.

Dessa forma, como propõe Yassen *et al* (2017) em um problema de PPRP os componentes do VRPTW podem ser considerados: veículos – patrulhas; clientes – pontos de risco (*hotspots*); janela de tempo – tempo de permanência no local; capacidade do veículo – tempo máximo do turno de serviço.

Ainda, no tocante a utilização na Brigada Militar, Maciel *et al* (2021) propõem a utilização do VRPTW para roteirização de Patrulhas Maria da Penha, patrulhas policiais que devem realizar a visita de vítimas com medidas protetivas de urgência para fiscalizar o cumprimento da decisão judicial. Portanto, busca-se a minimização do custo de tempo das rotas para que possam ser otimizadas as visitas realizadas a cada serviço, sempre partindo de uma sede de batalhão e visitando uma vez cada vítima, por planejamento (roteirização).

A proposta resolveu o problema através da metaheurística Busca Tabu, questão que será apresentada posteriormente, utilizando a biblioteca OR-Tools em Python. Após a publicação, a implementação foi aplicada em uma unidade da Brigada Militar alcançando um incremento de mais de 53% na quantidade de visitas realizadas (GRUPO DE PESQUISA EM ANALYTICS – UFRGS, 2021). Destaca-se que a maior frequência permite uma maior prevenção a violência doméstica.

2.4.2 Heurísticas

Rodrigues *et al* (2011) descrevem que no processo de tomada de decisão, as pessoas normalmente se guiam por regras práticas, estratégias através das quais simplificam o processo de tomada de decisão, avaliando e pensando sobre o problema que deve ser solucionado, conhecidas como heurísticas. Logo, de forma geral, as heurísticas “fazem parte de nosso cotidiano, e são elementos essenciais para o auxílio em um processo decisório eficaz”,

permitindo às pessoas resolver problemas e fazer julgamentos rápida e eficientemente (RODRIGUES *et al*, 2011).

Nos processos de otimização, a busca pela solução de problemas de grande complexidade, que se apresentam de forma intratável computacionalmente, diante da insuficiência dos métodos exatos, tem levado ao desenvolvimento e aperfeiçoamento de estratégias eficientes para a solução de problemas np-hard de grande porte, sacrificando “o ideal de perfeição sugerido pela otimização em troca de melhorar a eficiência de um processo de busca” (TALBI, 2009; GOLDBARG *et al* 2016).

Enfim, as heurísticas na otimização são técnicas e métodos aproximativos com o objetivo de conseguir uma solução aceitável para determinado problema, utilizando um esforço computacional considerado razoável, gerando, em determinadas condições, “a viabilidade ou a otimalidade da solução encontrada” (GOLDBARG *et al* 2016). Para tanto, os métodos heurísticos executam uma “exploração relativamente limitada do espaço de busca e, normalmente, produzem soluções de boa qualidade em tempos de computação reduzidos” (SHARMA *et al*, 2018). Assim, uma solução aproximada e viável, pode ser tão significativa quanto a ótima, principalmente, se considerado que por vezes os dados de entrada também se tratam de aproximações (CAMPELLO, MACULAN, 1994)

Conforme Wolsey (1998) alguns fatores indicam a utilização de heurísticas, como: a necessidade de solução rápida (em alguns segundos ou minutos), a existência de uma instância tão complexa que não pode ser formulada em uma programação inteira ou inteira mista de tamanho razoável, e para certos problemas combinatórios (tais como roteamento de veículos e programação de máquinas), é fácil encontrar soluções viáveis através da análise ou conhecimento da estrutura do problema.

Heurísticas clássicas, consideram ideias simples como as conhecidas heurísticas gulosas ou míope. A ideia de uma heurística gulosa é construir uma solução a partir de um conjunto vazio, escolhendo a cada passo o item que apresenta a melhor decisão, a partir de um critério de otimização meramente local, até gerar a solução completa (CAMPELLO, MACULAN, 1994; WOLSEY, 1998; TALBI, 2009). Ressalta-se que “uma vez que um elemento é selecionado para fazer parte da solução, ele não é substituído por outro elemento, dessa forma não há retrocesso das decisões já tomadas”, caracterizando-se como um algoritmo determinista (TALBI, 2009).

Normalmente, são utilizadas como soluções iniciais ou para estabelecer os limites da otimização. Assim, heurísticas construtivas (partindo de um conjunto vazio de solução,

ordenadas a partir de uma função gulosa (*greedy*) poderão ser aperfeiçoadas (LAPORT *et al*, 2014). São exemplos de heurísticas construtivas: heurística do vizinho mais próximo, heurística da inserção da aresta barata.

De forma sucinta, para um problema de roteirização de veículo a construção de uma solução, a partir de uma heurística gulosa (vizinho mais próximo) segue a seguinte estrutura:

1º) definição do vértice inicial;

2º) escolher a cada iteração o vértice mais próximo ou de menor custo (de tempo por exemplo) do vértice em consideração (o último vértice inserido na rota), eliminando este do conjunto de possibilidades;

3º) os vértices são inseridos na rota até que não exista opção remanescente ou que tenha que se cumprir uma restrição, retornando a origem e iniciando-se uma nova rota a partir das etapas definidas (CAMPELLO, MACULAN, 1994).

Todavia, o avanço no estudo das heurísticas, gerou o surgimento de uma classe de estratégias amplas, a partir de procedimentos de alto nível para solução de problemas, com o foco em direcionar o processo de construção de heurísticas. sendo denominados de heurísticas modernas ou, como mais largamente difundido, metaheurísticas (GOLDBARG *et al* 2016). As metaheurísticas têm sido usadas em muitas aplicações de forma eficiente e eficaz para resolver problemas grandes e complexos, sendo que tal fato se deve principalmente a critérios contraditórios que são considerados: “exploração do espaço de busca”, buscando soluções em locais ainda não explorados (diversificação) e “exploração das melhores soluções encontradas” (intensificação) (TALBI, 2009).

Diante desses critérios, metaheurísticas mais apuradas, além de realizar buscas locais de soluções na vizinhança (soluções próximas a partir de um critério de movimentos definidos), realizam buscas em locais melhorados, a fim de escapar de ótimos locais e se aproximar, ou até mesmo atingir, ótimos globais (WOLSEY, 1998). Entre esse tipo de metaheurística, está a Busca Tabu, método utilizado em diversos problemas, mas reconhecido no tratamento da roteirização de veículos.

2.4.3 Busca Tabu

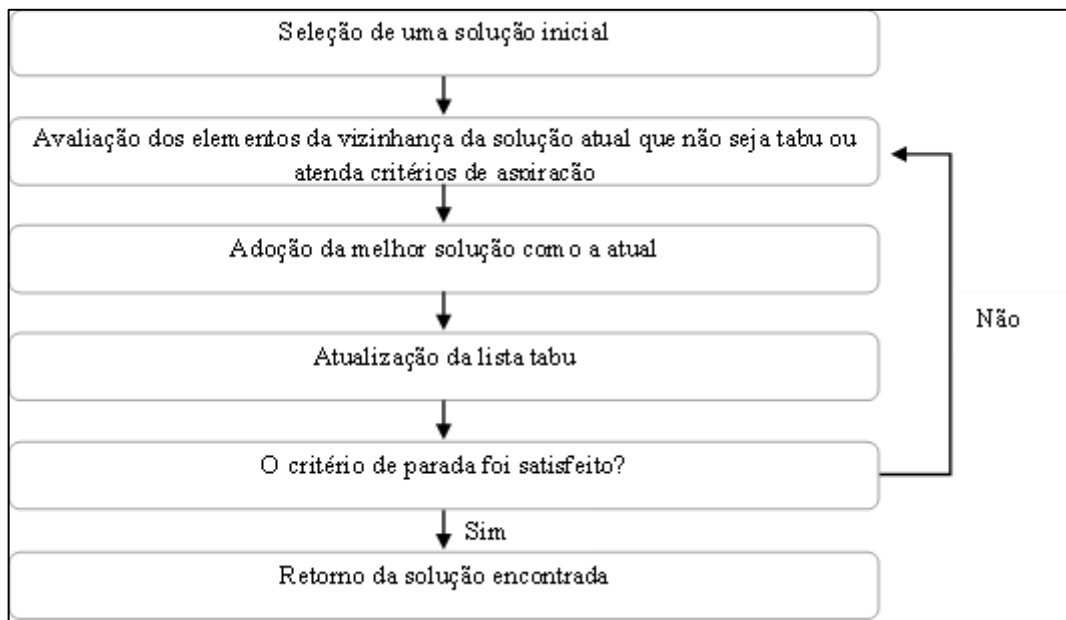
A Busca Tabu é um procedimento meta-heurístico proposto por Glover (1986) para resolver problemas de otimização, projetado para orientar outros métodos (ou seus processos componentes), com a ideia básica de evitar que a busca por soluções ótimas termine ao encontrar um ótimo local.

O autor partiu de uma abordagem de proibir certos movimentos, a fim de alcançar uma maior diversificação nas buscas, evitando a geração de ciclos que estagnassem a procura por melhores soluções, a partir de um ótimo local (GLOVER, 1986). O uso da memória, que as informações relacionadas ao processo de pesquisa, representa a característica particular da busca de tabu.

Partindo de uma solução inicial, a busca utiliza uma memória adaptativa para criar buscas mais flexíveis, sendo que o uso dessa memória, com as informações inerentes ao processo de busca, apresenta-se como uma característica particular dessa metaheurística (TALBI, 2009). Dessa forma, a Busca Tabu emprega uma “lista tabu” (lista de proibições), uma lista temporária de movimentos ou soluções já visitadas, que será utilizada para proibir movimentos que possam levar a soluções já conhecidas (vizinhos recentemente visitados). O método busca, a cada iteração, uma solução melhor em seu subconjunto da vizinhança, mesmo se esse causar uma piora na função objetivo (CORDEAU et al, 2001, TALBI, 2009). A figura 5 sintetiza o algoritmo do Busca Tabu.

A metaheurística da Busca Tabu tem sido utilizada em diversas configurações de problemas, apresentando soluções superiores às obtidas anteriormente através das melhores heurísticas existentes (GLOVER, 1990; GENDREU *et al*, 1994; CORDEU *et al*, 2001).

Figura 5 - Etapas do Algoritmo Busca Tabu



Fonte: adaptado de Wolsey (1998)

Nesse sentido, especificamente tratando do problema de roteirização de veículos, as pesquisas de Gendreu *et al* (1994) e Cordeu *et al* (2001), demonstram na comparação com

outras heurísticas, a partir de testes com instancias de Solomon e instancias da vida real, que as soluções obtidas através da Busca Tabu foram as melhores soluções, inclusive tratando da citada generalização do problema de roteirização de veículos com janela de tempo.

Além da qualidade das soluções, a Busca Tabu demonstra um tempo reduzido de processamento para gerar boas soluções. Tal característica, mostra-se fundamental para a utilização do método em soluções para policiamento, diante da flexibilidade do planejamento tático-operacional.

2.5 Modelo integrado de alocação e roteirização de patrulhas policiais

Conforme apresentado nas seções anteriores, diversos modelos têm sido desenvolvidos para a alocação e roteirização de patrulhas policiais, porém a proposição de modelos integrados que auxiliem no planejamento completo das atividades de policiamento com determinada finalidade ainda é reduzida.

Gurgel *et al* (2010) apresentam um modelo integrado de localização de bases policiais e roteirização de viaturas. O Modelo de Alocação e Roteirização de Novas Unidades Policiais considera as quantidades totais de ocorrências policiais na cidade de Natal, Rio Grande do Norte, e estabelece inicialmente uma proposta de localização de novas unidades policiais, a partir do método das p-medianas de forma que novos postos policiais sejam localizados na menor distância dos pontos de demanda, favorecendo a redução do tempo de resposta em chamadas de emergência.

Após a partir de uma modelagem de caixeiro viajante, estabelece a roteirização das unidades policiais entre os pontos de maior incidência criminal entre aqueles que devem ser cobertos por cada posto policial, demonstrando que a cobertura dos pontos com a nova alocação (configuração ideal) geraria menor custo de deslocamento se comparada com a localização atual. Assim, o modelo permitiria um aperfeiçoamento da segurança pública local, “com a redução do tempo de resposta e dos custos operacionais” (GURGEL *et al*, 2010).

Outro modelo que combina a cobertura de pontos e uma roteirização eficiente é proposto por Keskin *et al* (2012), problema de roteamento de patrulha e máxima cobertura (Maximum Covering and Patrol Routing Problem – MCPRP). Partindo de uma estratégia de resolução de um problema de orientação com janela de tempo, considerando dados de acidentes de trânsito, estabelece os hotspots que devem ser policiados e a solução do problema tem como objetivo maximizar o tempo de permanência nos pontos quentes.

Assim, decorre de uma seleção de pontos a serem policiados, e de acordo com a disponibilidade de recurso é traçada a rota que permita a permanência das patrulhas nos pontos de parada por mais tempo. Após a formulação utilizam a busca local e o Busca Tabu para a solução do problema (KESKIN *et al*, 2012).

Nesse modelo, embora apresente grande inovação e esteja em processo de aprimoramento, como observa-se em Çapar *et al* (2015) e Dewil *et al* (2015), alguns pontos podem deixar de ser policiados, como ocorre nos problemas de máxima cobertura e o tempo de permanência nos pontos é variável, permanecendo nos pontos até que se abra a próxima janela de tempo.

3 METODOLOGIA

3.1 Definição e contextualização da Área de Estudo

A pesquisa considerou uma região do município de Porto Alegre, capital do Rio Grande do Sul, Brasil. O município possui uma área de 496,8 km², com uma população de 1.488.252 de habitantes (IBGE, 2021), e tem exibido nas últimas décadas altos índices de homicídios, apresentando um aumento de 78% na quantidade de registros, entre os anos de 2011 e 2016, conforme dados da Secretaria da Segurança Pública Estadual, sendo que no final do ano de 2016 e início de 2017, com o agravamento dos crimes, o problema foi exposto de forma mais enfática pela mídia.


A imprensa nacional e local, na época, deram grande ênfase a situação, tratando a situação como um “desastre” e uma “barbárie”, discorrendo sobre o conflito entre facções na capital gaúcha e a sensação de impunidade, a partir do relato de casos de homicídios e latrocínios, e a análise de especialistas, que destacavam o aumento da brutalidade e violência nas ações, ficando mais uma vez evidente as ações dos grupos criminosos, como fator diretamente relacionado ao fenômeno (LIMEIRA *et al*, 2021).

A atuação das facções, especialmente, a partir de suas organizações no antigo Presídio Central de Porto Alegre (atualmente Cadeia Pública de Porto Alegre), pode ser observada, além das reportagens em pesquisas sobre o tema. Entre as observações, constatou-se que diante do aumento de conflitos entre os grupos criminosos (facções), houve uma ruptura na relação de “fidelidade da comunidade”, sendo que as lideranças (de outras comunidades) começaram a obter espaço, através da força e da ameaça. A esse fato, agrega-se a multiplicidade de grupos criminais, os quais tinham nos presídios um de seus focos de expressão e, nos bairros, outro, intensificando a lógica de expansão territorial buscadas pelas facções, utilizando a “violência explícita como método central” (CIPRIANI, 2016).

Analisando as informações de registros de homicídios, em números absolutos, disponibilizados pela Secretaria da Segurança Pública (Figura 6), nota-se a variação de ocorrências na última década. Os números demonstram um aumento de 83% no número de ocorrências de homicídio no município de Porto Alegre, entre os anos de 2011 e 2016. Nota-se que o aumento não se mostrou gradual, considerando-se o ano anterior, sendo verificado um aumento de 20% em 2012, 26% em 2014, 4% em 2015 e 19% em 2016, sendo que no ano de 2013 não houve aumento, havendo uma redução de 2% considerando o número de ocorrências

do ano anterior. Assim, encontra-se um aumento acumulado de 48% entre os anos de 2011 e 2014, e um incremento no número de homicídios no percentual de 24%, entre 2014 e 2016.

Figura 6 - Gráfico do Total de Ocorrências de Homicídios Consumados em Porto Alegre (2011 – 2020)



Fonte: elaborado pelo autor, dados da Secretaria da Segurança Pública/RS (2021)

Todavia, a partir da implementação de ações de aprimoramento de gestão como a implementação do Programa Avante (programa de gestão de processos e resultados da Brigada Militar – Polícia Militar Estadual), a organização do Observatório Estadual da Segurança Pública, o aperfeiçoamento do sistema de registro de ocorrências, além da intensificação de operações e ações de enfrentamento as organizações criminosas, houve uma redução dos números a partir de 2017, sendo constatada uma redução de 18% no número de registros, em comparação ao ano anterior (LIMEIRA *et al*, 2021).

Observa-se que a redução foi ainda mais relevante nos anos de 2019 e 2020, a partir do desenvolvimento do Programa RS Seguro que atua com foco territorial, em áreas com indicadores de maior criminalidade e vulnerabilidade socioeconômica, tendo como um de seus eixos o combate ao crime, priorizando municípios com maiores indicadores criminais, realizando a gestão estatística em segurança (GESEG) e o monitoramento de indicadores, através do ciclo mensal de reuniões do GESEG (SECRETARIA DA SEGURANÇA PÚBLICA, 2021). Embora seja necessário considerar alguma influência da pandemia do COVID-19 (diante da restrição de funcionamento de estabelecimentos e circulação ao longo do ano de 2020), nota-se que a no ano de 2019 (anterior a pandemia) houve a maior redução do índice: 37%.

Contudo, apesar das reduções a taxa de homicídios no município no ano de 2020 foi de 18,6 homicídios/100 mil habitantes (SECRETARIA DA SEGURANÇA PÚBLICA, 2021), ainda muito superior à taxa global que foi de 6,1 homicídios/100 mil habitantes (2017), sendo que o índice no município de Porto Alegre chegou a 55,64 homicídios/100 mil habitantes no ano de 2017(IPEA, 2020).

A presente pesquisa teve como foco a área de responsabilidade territorial do 1º Batalhão de Polícia Militar, compreendendo 27 bairros no município de Porto Alegre, correspondendo a uma área de cerca de 84,64 km² (17% da área do município), com uma população cerca de 400 mil habitantes (aproximadamente de 28% da população total da cidade).

Figura 7 - Mapa da Área do Batalhão de Polícia Militar

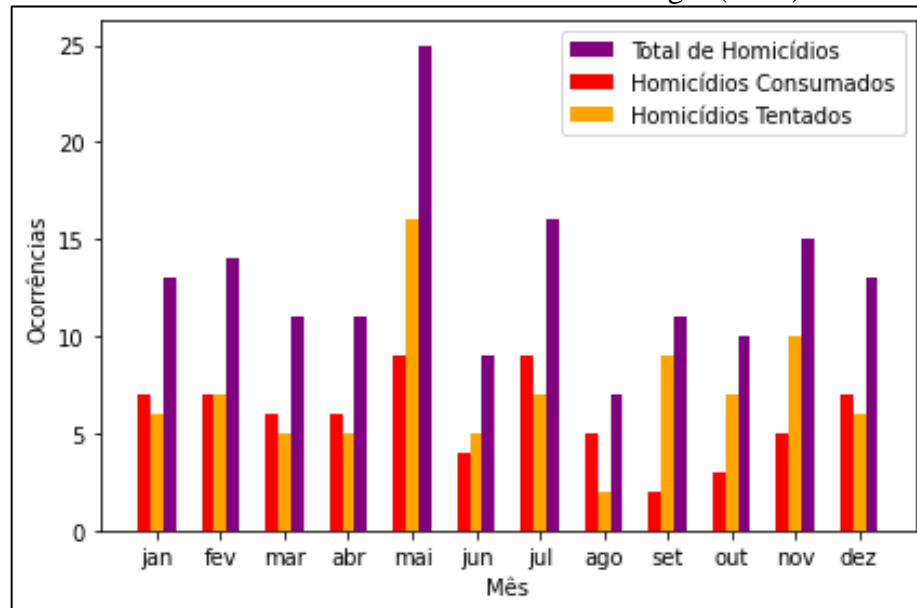


Fonte: autor (QGIS) - Shapefile (Bairros de Porto Alegre – OBSERVAPOA)

No aspecto criminal, a região delimitada correspondeu no ano de 2020, como área de responsabilidade territorial (circunscrição do órgão policial militar) com maior quantidade de ocorrências de homicídios no estado, totalizando 155 eventos, sendo 70 consumados e 85 tentados, conforme distribuição da Figura 8.

Conforme dados analisados, as ocorrências na área de responsabilidade do órgão policial militar, representam 28% dos homicídios registrados na capital rio-grandense no ano de 2020, sendo a área do estado com maior número absoluto de eventos dessa natureza.


Figura 8 - Gráfico do total de ocorrências de homicídios consumados e tentados na área do 1º BPM- Porto Alegre (2020)



Fonte: elaborado pelo autor, dados da Secretaria da Segurança Pública/RS

Analisando quanto ao horário de incidência, constata-se que 96 ocorrências (62%) do total no ano de 2020, aconteceram entre 17h e 1h, evidenciando-se uma concentração das ocorrências num período de 8 horas.

Figura 9 - Distribuição de ocorrências de homicídios no 1º BPM, por faixa horária (2020)



Fonte: elaborado pelo autor, dados da Secretaria da Segurança Pública/RS

A fim de compreender melhor a problemática, realizou-se a análise de distância dos homicídios com ocorrências anteriores, considerando um período de análise de três meses anteriores ao mês de verificação. Dessa forma, avaliou-se que as ocorrências envolvendo armas de fogo e tráfico de drogas, indicam as áreas de atividade de gangues e pontos de vendas de drogas; e ocorrências de lesão corporal indicariam as áreas em que existia um ambiente propício para a violência interpessoal e solução violenta de conflitos do cotidiano, fatores indicados em pesquisas anteriores na busca pelo entendimento e previsão de homicídios.

Os dados coletados, através do sistema da Brigada Militar/Secretaria da Segurança Pública, permitiram a elaboração dos gráficos a seguir, que demonstram a relação dos fatos correlatos dos períodos de análise (trimestre anterior – dados de outubro de 2019 a dezembro de 2020) com os homicídios, considerando dados mensais referentes ao ano de 2020:

Figura 10 - Gráfico de homicídios e ocorrência de arma de fogo mais próxima (3 meses anteriores - km) *

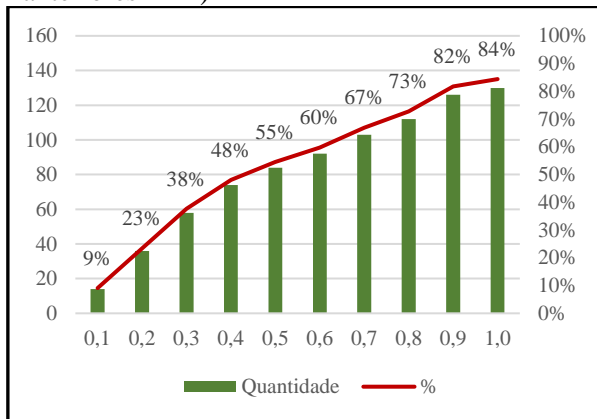


Figura 11 - Gráfico dos homicídios e ocorrência de tráfico de drogas mais próxima (3 meses anteriores - km)




Figura 12 - Gráfico dos homicídios e ocorrência de lesão corporal mais próxima (3 meses anteriores - km)


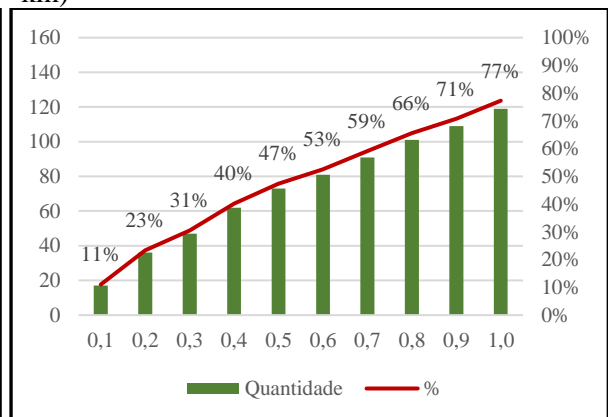


Figura 13 - Gráfico dos homicídios e outro homicídio mais próximo (3 meses anteriores - km)



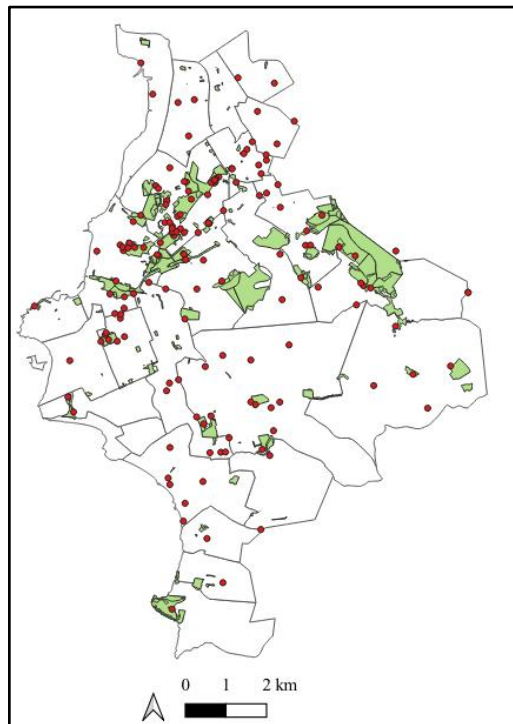
Fonte: elaborados pelo autor. Dados: Secretaria da Segurança Pública/RS

(*) ocorrências de arma de fogo compreendem os registros de porte ilegal de arma de fogo, posse irregular de arma de fogo, posse/porte ilegal de arma restrita, disparo de arma de fogo, comércio ilegal de arma de fogo, fornecimento de arma/munição e localização de arma.

Através da análise dos gráficos percebe-se que os homicídios acontecem, em sua maioria, em locais em que se identifica a atuação do crime organizado, através do tráfico de drogas e ocorrências com armas (55% dos eventos de homicídios ocorreram em ponto localizado até 500 metros de pelo menos uma ocorrência de arma de fogo ou e 68% aconteceram em local a menos de 500 metros de ocorrência de tráfico de drogas no trimestre anterior), e ambiente de amplo registro de violência interpessoal (92% dos registros de homicídios aconteceram em locais a menos de 500 metros de pelo menos uma ocorrência de lesão corporal nos três meses anteriores). Ademais, considerando homicídios anteriores, nota-se que o percentual é de 47%, considerando a distância de até 500 metros de fato anterior e 77% a menos de 1km de evento anterior, também no período de análise de três meses.

Ainda, quanto aos fatores de risco, encontra-se nos estudos a identificação de áreas de vulnerabilidade. Quanto a isso, utilizou-se mapa do Observatório da Cidade de Porto Alegre (OBSERVA POA) que apresenta as localizações de vulnerabilidades considerando: aglomerados subnormais (unidades habitacionais caracterizadas por ausência de título de propriedade e pelo menos uma característica irregular: carência de serviços públicos essenciais e/ou irregularidade das vias de circulação e do tamanho, e forma dos lotes), vilas demarcadas e áreas de risco.

Figura 14 - Mapa de estudo com áreas de vulnerabilidade e homicídios no ano de 2020



Fonte: elaborados pelo autor – shapefile Áreas de Vulnerabilidade (OBSERVA POA, 2017)

Assim, a partir da alocação dos homicídios no mapa das áreas de vulnerabilidade (considerando o espaço em estudo), verificou-se que 33,5% dos eventos de homicídios, na região do batalhão, ocorreram nos limites consideradas de vulnerabilidade.

Importante destacar que, durante o ano de 2020, ocorreu a pandemia decorrente do COVID-19, sendo que o município de Porto Alegre sofreu grandes alterações em sua dinâmica social, em virtude de grandes períodos em que houve restrições de funcionamento de estabelecimentos, totais (período integral) e parciais (determinados horários), gerando que algumas atividades fossem completamente restritas, como acesso a rede escolar e realização de eventos com grande concentração de pessoas, como eventos esportivos e artísticos. Portanto, tal situação foi ser considerada quanto a definição de fatores criminógenos.

Destarte, a utilização de modelo de policiamento inteligente, com o objetivo de indicar e propor a atuação nos pontos com maior risco de ocorrências de homicídios, justamente, na área de maior concentração desse delito no Rio Grande do Sul, apresenta-se como uma relevante alternativa para o aprimoramento das ações da administração pública e das polícias para a redução dos índices e para a garantia de uma maior segurança à população.

3.2 Modelagem de Planejamento de Policiamento Inteligente

Destaca-se que a atividade de policiamento ostensivo (caracterizado pela percepção da presença policial, a partir do fardamento e identificação das viaturas), e que no Brasil é realizado pelas polícias militares, em sua rotina agrega atividades de atendimento de ocorrências (a partir do chamados de emergência, diante de fatos em andamento ou já praticados), de fiscalização (como é o caso de patrulhas Maria da Penha que fiscalizam o cumprimento de medidas judiciais aplicadas) e de prevenção (função principal para a garantia da ordem pública, a partir da ação de presença).

Logo, a proposta que se realiza decorre da necessidade de otimizar o planejamento tático-operacional de alocação e roteirização de patrulhas com o mote de prevenir homicídios na área de estudo, a partir da ação de presença nos locais com maior risco de ocorrência desse delito.

A proposição trata da definição de um modelo de policiamento inteligente para a área definida, em duas fases: um modelo de localização de patrulhas com ênfase na predição (alocar a viatura policial nos locais onde há maior risco de ocorrência do fato criminoso em foco) e um modelo de roteirização das patrulhas para um maior aproveitamento do tempo de serviço,

reduzindo os deslocamentos, permitindo a cobertura dos pontos definidos com a menor quantidade de recursos.

Figura 15 - Modelo de Policiamento Inteligente



Fonte: elaborado pelo autor.

3.3 Modelo de Localização de Patrulhas

A pesquisa do modelo de localização de patrulhas policiais teve como mote a determinação de um modelo que pudesse indicar com maior grau de acerto os pontos de maior risco, referente às ocorrências de homicídios. Para tanto, partiu-se do modelo preditivo do RTM, bem como aplicou-se três outros métodos utilizados para localização de facilidades: um modelo k-means, um modelo de p-medianas e um modelo localização de máxima cobertura.

Os padrões foram gerados para indicar os pontos de atuação de patrulhas e comparando-os com as ocorrências de homicídios dolosos (tentados e consumados), na área do Batalhão de Polícia Militar no período de janeiro de 2020 a junho de 2021, conforme parâmetros e formulações detalhados a seguir. Salienta-se que nesse estudo não foram considerados os crimes de feminicídios (homicídios decorrentes de violência doméstica contra mulher), uma vez que possuem tipo penal específico e o estudo de seus fatores é diverso dos crimes de violência geral.

A escolha do período decorre do aperfeiçoamento dos registros policiais a partir do ano de 2019, com a implantação de novo sistema, o qual destaca a importância para a geolocalização dos pontos de ocorrência, ao invés da disposição do endereço em campo aberto, que dificultava a identificação da localização exata/próxima dos fatos delituosos.

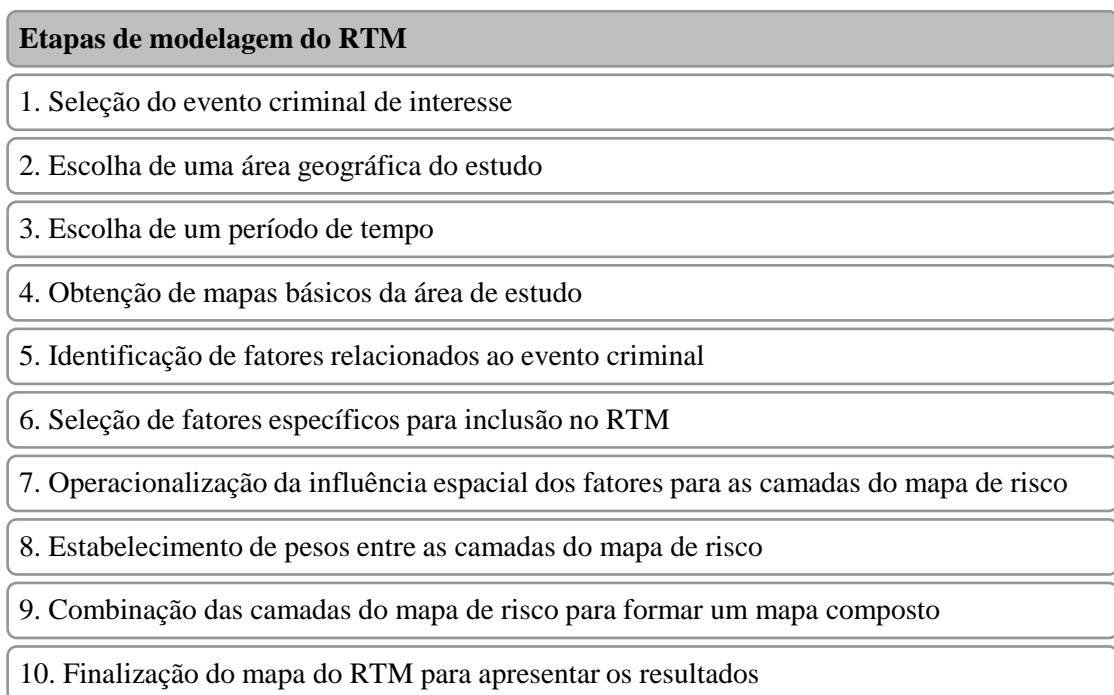
Assim, no ano de 2019 já foram obtidos índices relevantes, sendo que o percentual de registros sem geolocalização foram de 2% para os crimes de homicídios, 3% para crimes envolvendo armas de fogo, 4% para registros de tráfico de entorpecentes e 2% para fatos de lesão corporal. No ano de 2020, a quantidade de ocorrências sem dados de coordenadas geográficas foi somente 0,2% em média, para os tipos penais citados. Destaca-se que referente a área definida 100% dos dados estavam geocodificados

3.3.1 Modelo RTM

O modelo de localização de patrulhas a partir do RTM, considera que com a identificação dos grids com maior risco, a partir dos fatores correlatos, pode-se alocar patrulhas no centro dessas unidades geográficas, e a partir dessa atuação, a aumentar a possibilidade de prevenção de possíveis homicídios na área de ação da unidade operacional.

Quanto ao método de implementação do RTM apresenta 10 etapas para a modelagem do RTM, conforme figura 16, as quais serão detalhadas na sequência.

Figura 16 - Etapas da modelagem do RTM



Fonte: adaptado de Caplan *et al* (2011)

1) Seleção do evento criminal de interesse

Ocorrências de homicídios (consumados e tentados).

2) Escolha de uma área geográfica do estudo

Área do 1º Batalhão de Polícia Militar, situado em Porto Alegre.

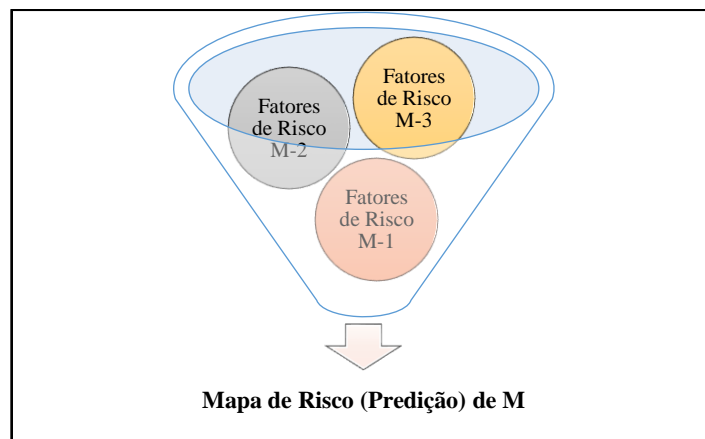
3) Escolha de um período

A implementação considera o período de janeiro de 2020 a junho de 2021, com o período de análise dos fatores correlatos, para cada mapa de risco, o trimestre anterior ao mês de análise. Assim, considerando a proposição dos desenvolvedores do método, principalmente, no que concerne a flexibilidade quanto as realidades locais, a pesquisa propõe uma novidade em relação as aplicações do RTM localizadas, quanto ao período de previsão. Como

apresentado, a utilização do RTM considera, normalmente, uma base de dados de um longo período (semestre ou ano) para a realização de previsão de crimes para período equivalentes (semestre ou ano), sendo que Kennedy *et al* (2011), utilizaram a referência de dados trimestrais para a previsão de um trimestre.

No entanto, sugere-se a implementação do método para a previsão de ocorrência de homicídios específico para cada mês, considerando dados de referência dos três meses anteriores (considerando período de influência proposto por Kennedy *et al* (2011)). A proposta decorre da sistemática desenvolvida pelos programas estaduais de acompanhamento de indicadores - Programa Avante (da Brigada Militar) e Programa RS Seguro (Secretaria da Segurança Pública) – que compreendem ciclos mensais de reuniões de avaliação e planejamento. Assim, sendo M o mês para a previsão dos crimes, serão utilizados para a análise preditiva RTM dados dos fatores correlatos de M-3, M-2 e M-1.

Figura 17 - Relação dos fatores para previsão de curto período (mês)



Fonte: elaborado pelo autor

4) Obtenção de mapas básicos da área de estudo

O mapa de Porto Alegre encontra-se disponível no sítio eletrônico do Observa POA (Observatório da Cidade de Porto Alegre), sendo que através do sistema QGIS foi editado mapa da área da unidade operacional em estudo e divididas nas unidades padrões de análise (grids), de 500 m de aresta cada.


O tamanho do grid/célula de análise trata-se de um aspecto importante para a implementação do método. Da maneira apresentada, há uma variedade de dimensões utilizadas anteriormente, partindo da ideia de micro nível, considerando as dimensões dos quarteirões das localidades. Contudo, Dugato *et al* (2020), realizando a previsão de homicídios pela máfia, utilizou uma grade regular com células de tamanho de 1km X 1km, apresentando três

argumentos para a definição: o crime escolhido trata-se de “evento esporádico cuja localização é afetada por uma variabilidade estocástica”, a maioria dos homicídios da máfia ocorre em locais públicos que corroboram para a imprecisão da localização e, no caso do crime de homicídios, “intervenções ou políticas preventivas devem se concentrar em áreas maiores da cidade em vez de micro lugares”.

Observando os argumentos, nota-se que todos mostram-se adequados à realidade e ao contexto dos homicídios na região sob análise. Quanto à quantidade de eventos no trabalho citado, a previsão considerou o período de um ano, no qual foram registrados 20 homicídios pela máfia, sendo que o presente estudo considerará a previsão mensal de homicídios, que no ano de 2020, foi em média 13 ocorrências por mês.

Portanto a área do batalhão foi dividida em células padronizadas (500m X 500m), utilizando o sistema QGIS, totalizando 402 grids de análise:

Figura 18 - Mapa da Área de Estudo Dividido por Grids (500m X 500m)



Fonte: elaborado pelo autor – QGIS

5) Identificação de fatores relacionados ao evento criminal

Após análise da bibliografia, sobre as causas dos homicídios no país e, especificamente, no município de Porto Alegre nos últimos anos, observa-se que os crimes de homicídios e tiroteios envolvem um padrão de fatores correlatos, como se vê:

- vulnerabilidade social, desordem urbana e habitações de risco (CERQUEIRA, 2005; KENNEDY *et al*, 2011; GELISKI NETO, 2012; ENGEL *et al*, 2015; VALASIK *et al*, 2019);

- atividade de gangues e tráfico de drogas (CAPLAN *et al*, 2011; KENNEDY *et al*, 2011; GELISKI NETO, 2012; SAPORI *et al*, 2012; FROTA, 2014; ENGEL *et al*, 2015; BULLA *et al*, 2016; DUGATO *et al*, 2020);

- ocorrências de armas de fogo (KENNEDY *et al*, 2011; ENGEL *et al*, 2015);

- violência interpessoal, sociabilidade violenta, solução violenta de conflitos do cotidiano (SAPORI *et al*, 2012; ENGEL *et al*, 2015; BULLA *et al*, 2016).

- homicídios anteriores (DUGATO *et al*, 2020).

Ainda, outras pesquisas do RTM (CAPLAN *et al*, 2011; GIMÉNEZ-SANTANA *et al*, 2018; VALASIK *et al*, 2019) agregam como fatores de risco estabelecimentos geradores e atratores para o crime de homicídios, como bares, boates, bancos, comércio, escola, restaurantes, lojas de bebidas, entre outros. Porém, como exposto, aqui encontra-se um limitador da pesquisa, uma vez que diante da pandemia do COVID-19, ao longo dos anos de 2020 e 2021, o funcionamento desses estabelecimentos foram afetados, seja pelo impedimento total ou em horários específicos das atividades, a partir de regulamentações do município e do estado que alteravam para cada período.

Assim, foram considerados fatores de risco correlatos aos eventos e homicídios:

- zonas de atuação de gangues e tráfico de drogas: locais de registros de ocorrências de tráfico de entorpecentes;

- locais de violência interpessoal e de conflitos violentos cotidianos: locais de eventos de lesão corporal;

- pontos de incidência de homicídios: locais de ocorrências de homicídios anteriores (consumados ou tentados);

- lugares de ocorrências de arma de fogo: pontos de fatos criminais de arma de fogo (porte ilegal ou irregular, disparo de arma de fogo, comércio ilegal de arma de fogo, fornecimento de arma/munição e localização de arma;

- áreas de vulnerabilidade: aglomerados subnormais, vilas e áreas de risco.

6) Seleção de fatores específicos para inclusão no RTM

Antes da aplicação dos fatores elencados na modelagem do risco terreno, foi realizada a testagem acerca da relação dos fatores de risco com o crime de homicídio, através de uma análise de regressão binomial negativa. Assim, utilizou-se o período entre janeiro e dezembro de 2020 (período de treinamento, considerando a contagem, em cada um dos 402 grids, de ocorrências de cada um dos fatores de risco no trimestre anterior ao mês de verificação e

quantidade de homicídios no mês de verificação, assim, foi organizada a uma matriz para os doze meses com dados dos 402 grids (totalizando 4.824 linhas de análise).

Após a organização dos dados, realizou-se regressão binomial negativa através da biblioteca Numpy e do pacote Scipy, em Python. O pacote Scipy apresenta ferramentas dedicadas a problemas comuns em computação científica, sendo utilizado o submódulo de estatística (scipy.stats).

Tabela 1 - Resultados do Modelo de Regressão Linear Generalizado

Dep. Variable: hom_b	No. Observations: 4824					
Model: GLM	Df Residuals: 4818					
Model Family: NegativeBinomial	Df Model: 5					
Link Function: log	Scale: 1.0000					
Method: IRLS	Log-Likelihood: -588.57					
Date: Sun, 13 Mar 2022	Deviance: 772.35					
Time: 18:14:09	Pearson chi2: 4.31e+03					
No. Iterations: 7						
Covariance Type: nonrobust						
	coef	std err	z	P> z	[0.025	0.975]
Intercept	-4.6465	0.182	-25.466	0.000	-5.004	-4.289
arm	0.1790	0.073	2.467	0.014	0.037	0.321
tra	0.2425	0.089	2.735	0.006	0.069	0.416
hom	0.1537	0.073	2.102	0.036	0.010	0.297
les	0.3681	0.090	4.081	0.000	0.191	0.545
vul	0.8827	0.223	3.966	0.000	0.446	1.319

Fonte: elaborado pelo autor (Scipy)

A análise de regressão no RTM tem como objetivo, a partir dos valores-p dos coeficientes, determinar quais fatores devemos manter no modelo. Assim, um valor-p menor do que 0,05 (baixo), indica que o fator, provavelmente, será uma adição significativa ao seu modelo, apresentando-se como significantes estatisticamente. Nota-se que os fatores apresentados, possuem valor-p baixo, sendo mantidos todos no modelo aplicado.

7) Operacionalização da influência espacial dos fatores para as camadas do mapa

Para cada mês de análise foram plotadas as ocorrências a partir dos registros policiais de cada indicador, a partir do trimestre anterior para definição do risco para mês sob análise, estabelecendo-se uma camada de contagem nos grids definidos para cada fator para cada mês. Foi utilizado o sistema QGIS para a alocação dos dados de ocorrências e contagem de incidências.

8) Estabelecimento de pesos entre as camadas do mapa de risco

Como proposto em outros estudos, foram utilizados os coeficientes de regressão, calculados a partir do risco no período do ano de 2020, como peso aos índices de risco de cada

fator para a produção dos mapas de RTM do período de 2020 (treinamento) e 1º semestre de 2021), da forma que segue:

Tabela 2 - Quadro de pesos dos fatores de risco do modelo

Fator	Peso
lugares de ocorrências de arma de fogo	0,1790
zonas de atuação de gangues e tráfico de drogas	0,2425
pontos de incidência de homicídios	0,1537
locais de violência interpessoal e de conflitos violentos cotidianos	0,3681
áreas de vulnerabilidade: aglomerados subnormais, vilas e áreas de risco.	0,8827

Fonte: elaborado pelo autor

9) Combinação das camadas do mapa de risco para formar um mapa composto

No que se refere aos fatores correlatos, considerados a partir de dados de significância, realizou-se o cálculo do escore risco: a contagem de incidência em cada grid, no período do trimestre anterior ao mês de previsão, para cada um dos fatores. Assim, foram elaboradas camadas independentes, considerando a densidade de incidência nos grids.

Dessa forma, os pontos foram alocados nos grids, para cada uma das camadas, realizando-se a contagem de incidência, formando-se uma matriz de densidade, avaliando todos os grids definidos.

Assim, primeiramente, calcula-se o escore de densidade (ED) cada grid, em cada uma das camadas, considerando o período de análise e a contagem de incidentes, da seguinte forma:

$$ED_{fg} = \frac{(I_n - MI)}{DP} \quad (\text{Equação 12})$$

Onde:

- *ED*: escore de densidade
- *I*: incidência no grid
- *MI*: média de incidência nos grids da área de estudo
- *DP*: desvio padrão
- *g*: grid em análise
- *f*: fator de risco em análise

Após, classificou-se os grids, a partir do estabelecimento do escore de risco (ER) para cada fator (*f*) e cada grid (*g*). Quanto a essa graduação do escore de risco (ER_{fg}), utilizou-se a proposição de Caplan *et al* (2011) para classificação dos grids:

Tabela 3 - Graus de Risco por Camada no RTM

Escore de Risco (ER)	Descrição
0	Valores abaixo da média de incidência para o fator ($ED < média$)
1	Valores entre a média e o +1 desvio padrão ($média \geq ED > média + 1DP$)
2	Valores entre +1 desvio padrão e + 2 desvios padrões ($média + 1DP \geq ED > média + 2DP$)
3	Valores maiores do que 2 desvios padrões ($ED \geq média + 2DP$)

Fonte: elaborado pelo autor, com base em CAPLAN et al, 2011

Além do mais, se verifica a incidência das áreas de vulnerabilidade, fator identificado nos mapas como polígonos (delimitação geográfica), é a mesmo para todos os períodos de análise preditiva. No tocante a essas camadas de influência (áreas de vulnerabilidade) foram computados valores binários 0 ou 1, considerando a sobreposição das áreas de influência com cada grid.

10) Finalização do mapa do RTM para apresentar os resultados

Depois da formatação das camadas de risco para cada fator, o que no presente estudo foi realizado para cada mês de predição, passou-se a compilação das camadas e elaboração do mapa risco composto do RTM. Assim, calculou-se o valor de risco local (VRL), considerando os coeficientes de regressão como pesos de cada fator:

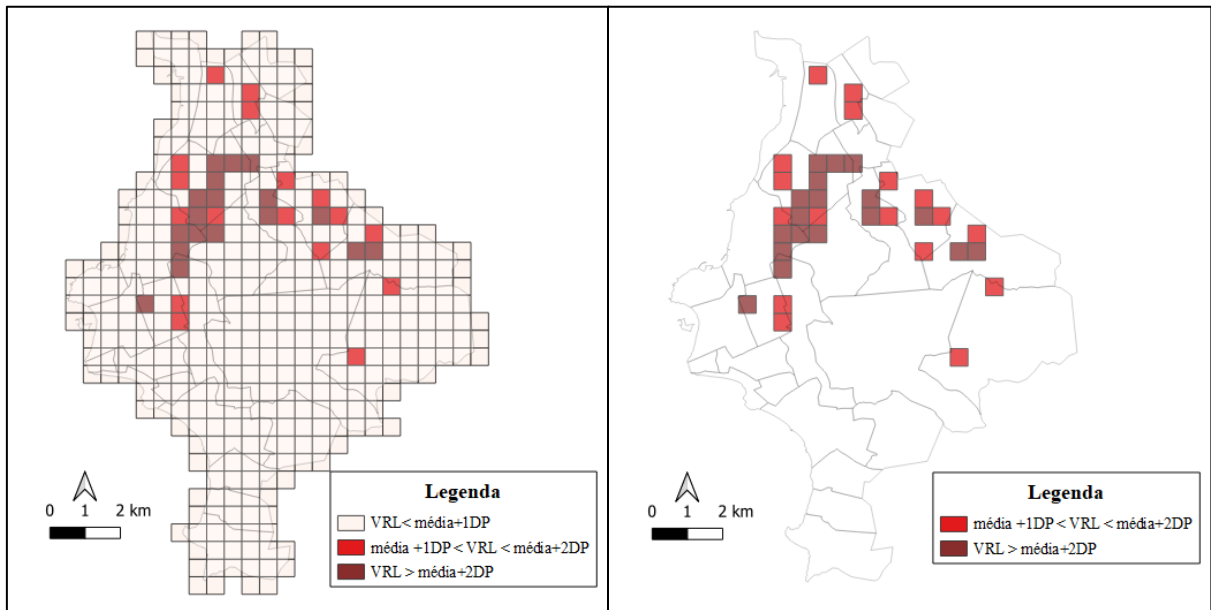
$$VRL_g = \frac{Exp(\beta_0 + \sum_{i=1}^n ER_{fg}\beta_f)}{Exp(\beta_0)} , \forall g \in (1, n), g \in \mathbb{Z} \quad (\text{Equação 13})$$

Sendo:

- VRL : valor de risco local
- ER : escore de risco de cada fator
- β : coeficiente de regressão
- g : grid em análise
- f : fator de risco

Assim, considerados os VRL de cada grid para cada mês, foram classificados como de altíssimo risco os grids com VRL iguais ou maiores a média dos VRL mais 2 desvios padrões, e de alto risco os grids com VRL igual ou maior a média dos VRL mais 1 desvio padrão e menor que a média e dois desvios padrões.

Figura 19 - Mapas finalizados com o RTM na área de estudo com os grids classificados com alto e altíssimo risco (mês de maio de 2021)



Fonte: elaborado pelo autor – QGIS.

Diante disso, chegou-se à tabela de resultados preliminares do modelo:

Tabela 4 - Resultados de acertos do modelo em RTM

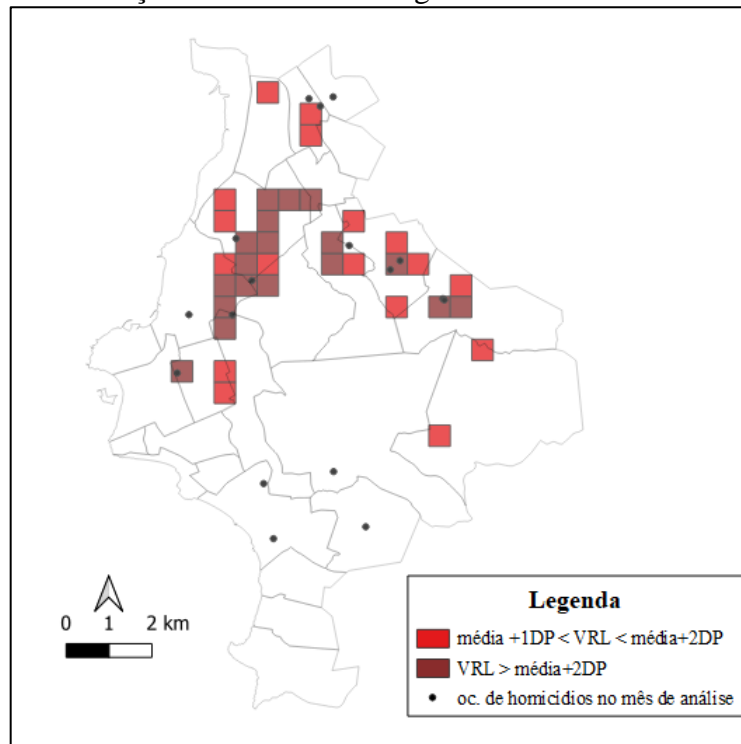
Mês	Nr Homicídios	Altíssimo Risco			Alto e Altíssimo Risco		
		Pontos	Acertos	Percentual	Pontos	Acertos	Percentual
jan/20	13	13	1	8%	37	4	31%
fev/20	14	21	5	36%	40	5	36%
mar/20	11	15	4	36%	32	6	55%
abr/20	11	17	3	27%	29	4	36%
mai/20	25	18	4	16%	35	8	32%
jun/20	9	18	4	44%	34	6	67%
jul/20	16	21	7	44%	37	9	56%
ago/20	7	18	1	14%	32	2	29%
set/20	11	17	3	27%	28	3	27%
out/20	10	18	4	40%	37	4	40%
nov/20	15	13	4	27%	35	8	53%
dez/20	13	12	3	23%	32	6	46%
jan/21	19	17	7	37%	32	8	42%
fev/21	8	17	3	38%	39	3	38%
mar/21	8	17	2	25%	25	2	25%
abr/21	15	14	2	13%	39	7	47%
mai/21	17	22	9	53%	44	9	53%
jun/21	16	15	2	13%	40	5	31%
Total	238	303	68	29%	627	99	42%

Fonte: elaborado pelo autor

Considera-se acerto quando os homicídios, no mês de análise, ocorreram dentro da área dos grids selecionados como alto ou altíssimo risco, sendo que no total do período, 28,6% dos homicídios ocorreram nos grids de altíssimo risco (em cada mês de análise) e 41,6% ocorreram nos grids de alto e altíssimo risco). Considerando somente o período de teste, no qual não foi realizada a regressão (1º semestre de 2021) os percentuais foram de 30,1% e 41,0%, respectivamente.

Nota-se que a média de pontos de altíssimo risco foi de 17 pontos, nos 18 meses, sendo que a média de pontos de alto e altíssimo risco foi de 34 pontos, no mesmo período, os quais compreendem, respectivamente, 5% e 10% da área total de estudo.

Figura 20 - Mapa finalizado com o RTM na área de estudo com os grids classificados com alto e altíssimo risco (mês de maio de 2021) e a localização dos homicídios registrados no mês de análise.



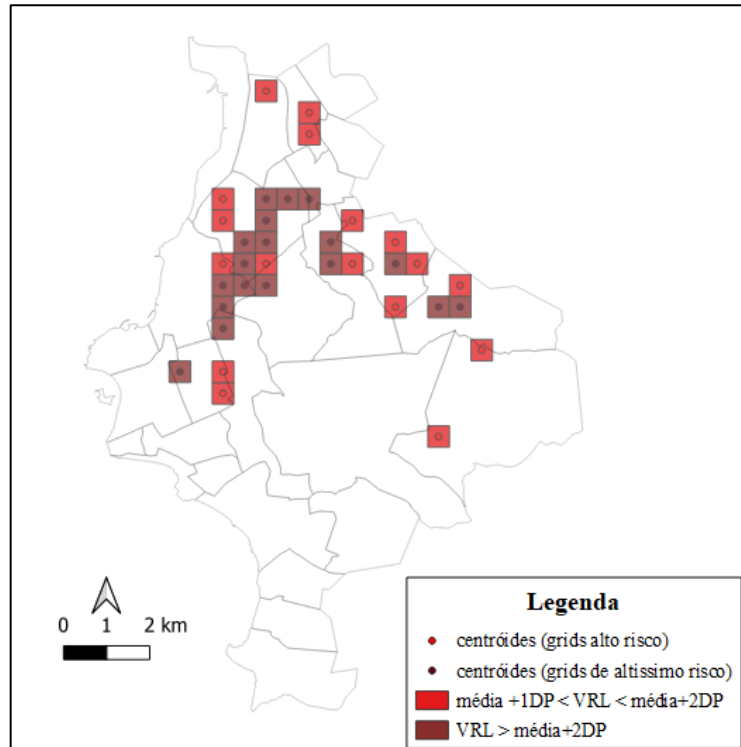
Fonte: elaborado pelo autor – QGIS.

Diante do exposto, realizou-se a implementação de outros modelos de localização de facilidades, a fim de comparar a capacidade preditiva, considerando os fatores de riscos aos modelos. Destaca-se que os modelos estudados (k-means, p-mediana e máxima cobertura) necessitam, entre seus parâmetros da determinação do número de pontos, logo, padronizou-se um modelo mensal com 17 pontos e outro com 34 pontos.

Ao final, ainda foi gerado um novo modelo de RTM definindo a mesma quantidade de pontos, a fim de permitir uma melhor comparação.

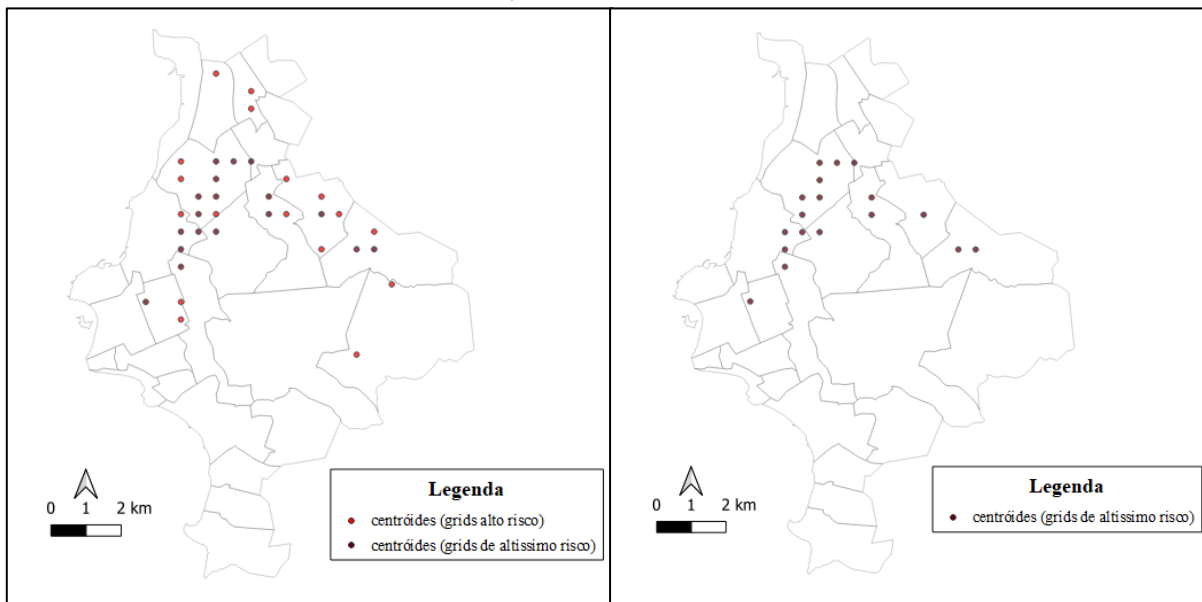
Ainda, salienta-se que como a próxima fase do modelo envolvia a produção de rota a partir de pontos fixos para a permanência das patrulhas, a aplicação gerou para cada mês de análise os centróides dos grids de maior risco definidos.

Figura 21 - Mapa com o RTM na área de estudo com os grids classificados com alto e altíssimo risco (mês de maio de 2021) e os respectivos centróides.



Fonte: elaborado pelo autor – QGIS.

Figura 22 - Mapa com o RTM na área de estudo com os centróides dos grids de maior risco (mês de maio de 2021).



Fonte: elaborado pelo autor – QGIS.

3.3.2 Modelo k-means

O modelo para estabelecer centroides considerando o método k-means, no presente trabalho, utilizou a biblioteca Sklearn, módulo cluster (sklearn.cluster), função kmeans, em Python. A biblioteca Scikit-learn apresenta-se como uma ferramenta de código aberto de aprendizado de máquina em Python, de forma simples, para análise preditiva de dados (PEDROSA *et al.*, 2011).

O submódulo k-means baseia-se na fundamentação do modelo que busca dividir o conjunto de amostras em clusters independentes, descrito pela média das amostras de cada um dos clusters. Assim, o k-means busca definir os centroides (os pontos centrais dos clusters) que minimizem a inércia, ou seja, o critério da soma dos quadrados na região externa do cluster.

A implementação da biblioteca segue as três etapas básicas do algoritmo, sendo a primeira a definição da quantidade e localização dos centroides iniciais. Na sequência inicia-se um looping nas demais etapas: atribuição de cada dado da amostra ao centroide mais próximo e a criação de novos centroides, a partir do ponto médio dos pontos de cada cluster, repetindo-se até que o valor seja menor que o limite definido.

Os dados das amostras utilizadas consideraram os pontos dos registros de homicídios, ocorrências com armas, tráfico de entorpecentes e lesões corporais do trimestre anterior a cada um dos meses de análise. Ou seja, utilizou-se para cada período de análise os mesmos dados de referência dos fatores criminais correlatos.

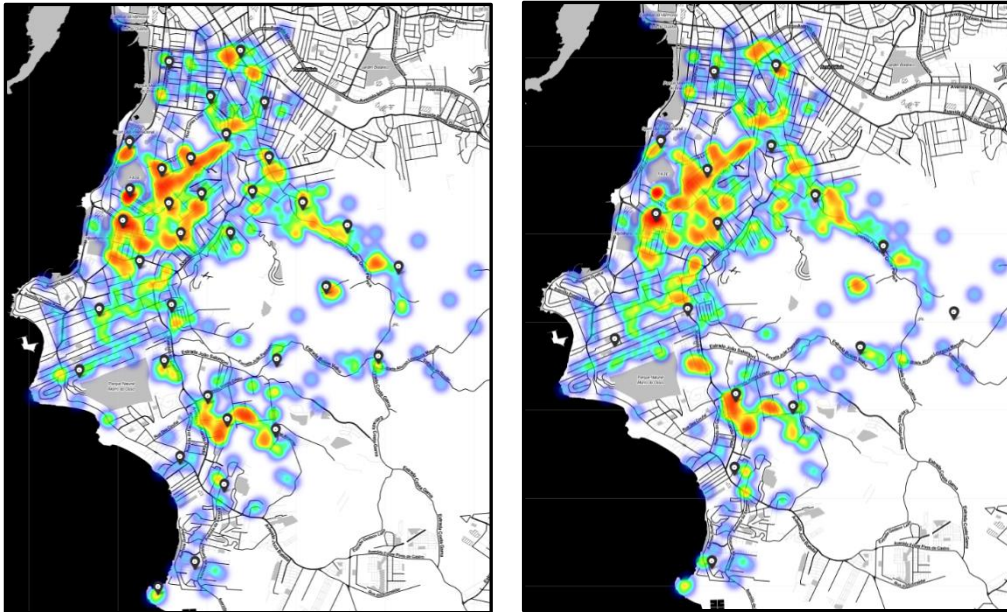
Assim, foram estabelecidos para cada mês de análise, respectivamente, $k = 17$ e $k = 34$ (número de centroides para cada período).

Além dos parâmetros de quantidade de centroides, a fim de reproduzir os testes de verificação para análise comparativa, estabeleceu-se como solução inicial (“centroides sementes”) as ocorrências de homicídios do período de influência (trimestre anterior) no limite da quantidade k estabelecida.

Os mapas a seguir, utilizando a ferramenta Folium, em Python, demonstram exemplos dentre os 18 meses de análise (no caso fevereiro de 2020), sendo que os primeiros dois mapas apresentam os pontos dos centroides propostos (34 e 17 pontos, respectivamente) e o mapa de calor considerando todas as ocorrências correlatas do semestre.

Na sequência, apresenta-se os mapas (Figuras 23 e 24) com os centroides e sua área de cobertura (definida como um raio de 300m) e os pontos de homicídios no mês de análise.

Figura 23 - Centróides k-means 34 e 17 pontos (mês de referência: fevereiro de 2020) e mapa de calor de amostra de ocorrências correlatas (novembro/2019 a janeiro /2020)



Fonte: elaborado pelo autor (Python/Folium)

Figura 24 - Centróides k-means 34 e 17 pontos (mês de referência: fevereiro de 2020)



áreas de cobertura e pontos de homicídios no mês de referência.

Fonte: elaborado pelo autor (Python/Folium)

3.3.3 Modelo p-medianas

O segundo modelo, para comparação com a localização através do RTM, utilizou método das p-medianas, problema clássico utilizado para a localização de facilidades, inclusive veículos de emergência e postos policiais.

Como já descrito, o problema das p-medianas tem como objetivo minimizar a distância dos pontos de localização das facilidades até os pontos de demanda. Assim, enquadra-se a necessidade de auxiliar na otimização de recursos limitados para atendimento de demandas determinadas, como é o caso das patrulhas policiais. Ocorre que o teste, por ora, visa comparar o potencial preditivo, ou seja, a partir das ocorrências correlatas identificar locais aproximados de ocorrências de homicídios na área e estudo.

Destarte, foram considerados os mesmos conjuntos de dados para a análise dos p pontos de cada mês de estudo (entre janeiro de 2020 e junho de 2021): os registros criminais de homicídios, lesões corporais, ocorrências com armas e crimes de tráfico de drogas (considerando os três meses anteriores ao mês de estudo).

Como parâmetro, foram utilizados em duas implementações, com $p = 17$ e $p = 34$, para cada mês de análise. Além do mais, o modelo exige a proposição de pontos de demanda (dados dos registros de todas as ocorrências correlatas do trimestre anterior) e pontos candidatos. No que se refere aos pontos candidatos, foram utilizados no modelo duas bases de dados diferentes: a primeira considerando todas as ocorrências correlatas (demanda) como pontos candidatos, e outra considerando somente os registros de homicídios, tráfico e crimes com armas (portanto, excluindo os crimes de lesões da base de locais candidatos).

Quanto a utilização de locais candidatos, dentre os pontos de demandas, já apresentamos referências fundamentando a sua aplicação.

Diante disso utilizou-se o modelo a seguir:

$$f(x) = \text{Min} \sum_{i=1}^n \sum_{j=1}^n d_{ij} x_{ij} \quad (\text{Equação 14})$$

Sujeito a:

$$\sum_{j \in D} x_{ij} = 1, \forall i \in C \quad (\text{Equação 15})$$

$$\sum_{i=0}^n y_i = p, \forall i \in C \quad (\text{Equação 16})$$

$$x_{ij} \leq y_i, \forall i \in C, \forall j \in D \quad (\text{Equação 17})$$

$$x_{ij}, y_i \in \{0, 1\}, \forall i \in C, \forall j \in D \quad (\text{Equação 18})$$

Sendo:

- C: conjunto de locais candidatos (sendo utilizado duas bases para implementações diversas, a partir dos dados do trimestre anterior a análise: a primeira considerando os registros

de homicídios, tráfico armas e lesões corporais; e o segundo, considerando homicídios, tráfico e armas – reduzindo o número de candidatos).

- D : conjunto de demanda (ocorrências correlatas) referente ao trimestre anterior ao mês de análise.

- x_{ij} : variável binária, sendo 1 se o ponto j é atendido pela facilidade no ponto i , e 0, caso o contrário.

- y_i : variável binária, sendo 1 se o ponto i está solucionado entre os pontos de alocação, e 0, caso o contrário.

- d_{ij} : distância entre os pontos i e j , respectivamente, no conjunto de locais candidatos e locais de demanda.

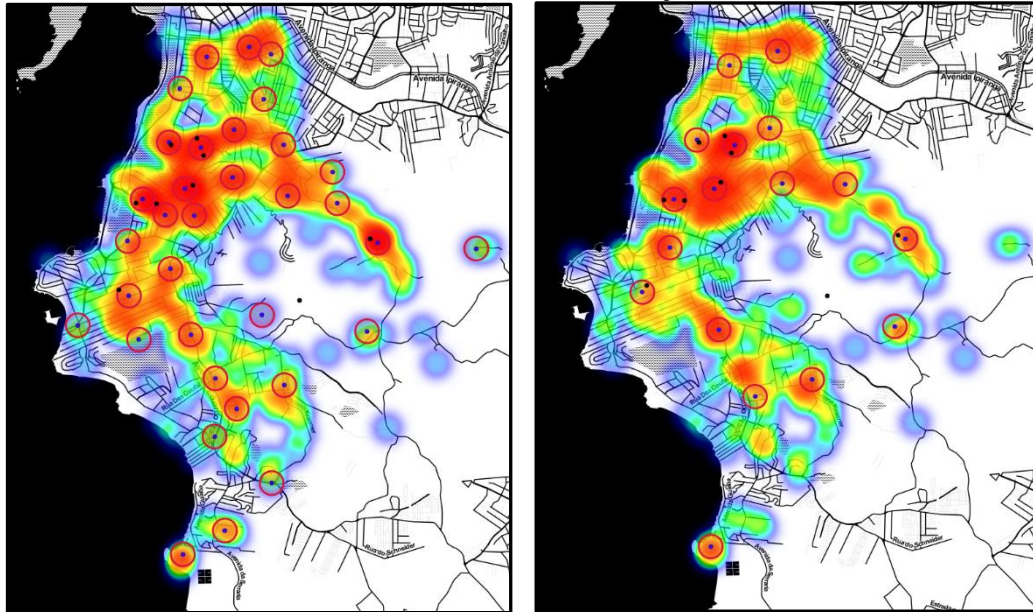
- p : número de locais de alocação de viatura, sendo rodados em duas implementações, com 17 e 34 pontos para cada mês.

No que se refere às restrições, segue-se o modelo original: estabelecimento de atendimento de todos os pontos da demanda por um local de alocação/facilidade (Equação 15); definição da quantidade de locais de alocação, sendo que a soma das variáveis binárias y devem ser iguais a p (Equação 16), vínculo cada um dos locais de ocorrências correlatas com um local candidato (Equação 17).

Para a aplicação do modelo de p -medianas foi utilizado o modelador de programação linear (PuLP/Python). O PuLP é um pacote de código aberto para Python para programação linear, podendo ser integrado a diversos solvers (PULP, 2021). No modelo foi utilizado o solucionador CBC (Coin-or Branch and Cut). Coin-OR (Computational Infrastructure for Operations Research) é um projeto de código aberto para desenvolvimento de “software de pesquisa operacional, a fim de acelerar o desenvolvimento e implantação de modelos, algoritmos e pesquisa computacional de ponta”.

Após a implementação nos 18 meses de análise, comparou-se os modelos, a partir da área de influência das p -medianas e os homicídios do mês de análise, sendo que considerando o modelo que utilizou todas as ocorrências correlatas como locais candidatos houve 16,4% de assertividade considerando 17 pontos e 38,7% para 34 pontos. Enquanto isso, no modelo que reduziu os pontos candidatos, excluindo os registros por lesões corporais o acerto (homicídios no mês de análise na área de cobertura – raio de 300m do ponto de alocação) chegou-se a 17,6% de acerto para 17 pontos e 39,1% para 34 pontos. Dessa forma, esse segundo modelo é que será utilizado no processo de análise comparativa, detalhando-se os resultados na seção específica.

Figura 25 - P-medianas 34 e 17 pontos (mês de referência: junho de 2020) e mapa de calor de amostra de ocorrências correlatas (março/2020 a maio/2020)



Fonte: elaborado pelo autor (Python/Folium)

3.3.4 Modelo de problema de localização de máxima cobertura (MCLP)

Finalmente, aplicou-se um modelo de cobertura, no processo de análise comparativa dos modelos para definição da melhor localização, com ênfase na predição. Conforme posto, o modelo de máxima cobertura, compreende na colocação de n pontos de facilidades com o objetivo de cobrir o maior número de pontos de demanda, considerando um custo (distância/tempo) máximo de relação.

Assim, o parâmetro de número de pontos definidos nos modelos, seguem os padrões já utilizados de 17 e 34 locais, respectivamente. Também a base de dados utilizada foi a mesma considerando para cada mês de análise os dados das ocorrências correlatas do trimestre anterior.

Como no modelo de p -medianas, utilizou-se duas bases de dados para os locais candidatos: a primeira considerando todas as ocorrências correlatas (ou seja, os mesmos pontos dos locais de demanda), e outra considerando os dados de ocorrências de homicídios, tráfico de drogas e ocorrências com armas.

Além dos parâmetros já tratados, o método necessita a definição do parâmetro de cobertura, sendo que foi utilizada a distância de 500m (0,5km), em virtude das áreas de cobertura de comparação com os demais modelos.

Da mesma forma que o modelo das p -medianas, utilizou-se o pacote PuLP em Python, com o solver CBC, realizando-se a implementação de acordo com os dados, parâmetros e formulação apresentada:

- Pontos de demanda ($D = 1, 2, 3, \dots, i$): pontos de ocorrências correlatas para o período de análise;
- Pontos candidatos ($C = 1, 2, 3, \dots, j$): conjunto de locais candidatos para o posicionamento da facilidade;
- Arcos ($A = \{(i, j) \in I \times J\}$): combinações entre os pontos candidatos e demanda;
- Número máximo de facilidades a utilizar (p): 17 e 34 em cada modelo do mês em análise.
- Distância máxima de cobertura (M): no modelo 500m (0,5km);
- Constante de cobertura (a): sendo 1 se o ponto de demanda i pode ser coberto pelo candidato j , caso contrário 0. Ou seja, se $d_{ij} \leq M$, então $a_{ij} = 1$, caso contrário $a_{ij} = 0$.
- Ainda são utilizadas duas variáveis binárias, sendo x_i (que será 1 se o ponto de demanda é atendido, e 0 caso inverso), e y_j (que será 1 se o ponto candidato faça parte da solução, e 0 caso inverso).

$$f(x) = \text{Max} \sum_{i \in D} x_i \quad (\text{Equação 19})$$

Sujeito a:

$$\sum_{j \in C} a_{ij} y_j \geq x_i, \forall i \in D \quad (\text{Equação 20})$$

$$\sum_{j \in C} y_j \leq p \quad (\text{Equação 21})$$

$$x_i, y_j \in \{0, 1\}, \forall i \in D, \forall j \in C \quad (\text{Equação 22})$$

Dessa forma, a função objetivo do modelo (Equação 19) é maximizar os pontos de demanda (ocorrências correlatas) atendidas pelos locais candidatos selecionados. Sendo que as restrições são as de que os pontos candidatos selecionados devem atender pontos de demanda em arcos de distância máxima de cobertura definida (Equação 20) e o número total de locais candidatos não pode ser maior o número máximo de facilidades estabelecido (Equação 21), além da definição das variáveis x e y como binárias (Equação 22).

No modelo de máxima cobertura, também a utilização do modelo com menor número de locais candidatos, aplicando-se no período de estudo, apresentou melhor resultado comparando a incidência de homicídios no mês de análise considerando os locais candidatos de cada mês de verificação, considerando as mesmas áreas de influência do k-means e p-medianas. No modelo, no qual os locais candidatos eram todos os pontos de demanda

(ocorrência correlata), constatou-se que em média 23,1% dos homicídios aconteceram na área de cobertura, considerando 17 pontos, sendo que quando gerados 34 pontos, o percentual de acerto foi de 31,9%. No tocante ao modelo no qual foram retirados dos locais candidatos os crimes de lesões, o percentual de acerto foi de 25,6% para 17 pontos, e 37,0% para 34 pontos. Portanto, este também foi o modelo para comparação de análise preditiva.

Cumprido ressaltar que, considerando a função principal da máxima cobertura o percentual de cobertura do modelo com mais possibilidades de localização foi melhor do que o segundo modelo: cobrindo em média 80,3% dos pontos de demanda, no primeiro modelo e 75,1, no segundo, para 34 pontos. Tratando-se de dezessete pontos o percentual do primeiro modelo foi de 57,6% e 54,4% o segundo, considerando 17 pontos.

O quadro, a seguir, apresenta os principais aspectos dos modelos executados e a forma de implementação.

Quadro 1 – Descrição dos métodos utilizados

Método	Objetivo	Parâmetros	Forma de implantação
K-means	Agrupar os pontos em k classes, a partir da minimização dos pontos ao centroide do cluster.	pontos: ocorrências correlatas (homicídios, lesões, armas e tráfico de drogas) – 3 meses	programação utilizando a biblioteca Sklearn, módulo cluster (sklearn.cluster), função kmeans, em Python
P-medianas	Minimizar a distância entre os pontos do grafo e as facilidades selecionadas (p).	pontos: ocorrências correlatas candidatos: ocorrências de homicídios, armas e tráfico – 3 meses p: 17 e 34	formulação utilizando o modelador de programação linear PuLP/Python. Solver CBC (Coin-or Branch and Cut)
MCLP	Maximizar o número de pontos cobertos pelas facilidades (p), considerando a distância máxima de cobertura(D).	pontos: ocorrências correlatas candidatos: ocorrências de homicídios, armas e tráfico – 3 meses p: 17 e 34 D: 500m	formulação utilizando o modelador de programação linear PuLP/Python. Solver CBC (Coin-or Branch and Cut)
RTM	Predizer grids com maior risco, a partir da compilação de camadas de fatores de risco.	fatores: ocorrências correlatas (homicídios, lesões, armas e tráfico de drogas) – 3 meses tamanho dos grids: quadrados de 500m de lado. grids de maior risco: 17 e 34	Elaboração e mapas e contagem de incidência utilizando QGIS

Fonte: elaborado pelo autor

3.4 Modelo de Roteirização de Viaturas

Na segunda fase do modelo de planejamento de atividades policiais preventivas, se propôs a utilização de um modelo de roteirização para as patrulhas considerando os pontos de posicionamento da primeira fase do modelo.

Ressalta-se que o estabelecimento de rotas de viaturas policiais pode se enquadrar no problema clássico de roteirização de veículos, pois partem da sede da unidade policial, passam por pontos definidos, no limite de tempo de serviço estipulado, e retornam a mesma base.

Logo, as patrulhas policiais têm um limite máximo de serviço, devem permanecer um tempo nos pontos de risco e realizar deslocamentos entre os pontos. Dessa forma, reduzindo o tempo de deslocamento entre os pontos poderão ser cobertos mais pontos pela mesma patrulha, além de reduzir custos de deslocamentos, uma vez que se priorizará as melhores rotas.

Como tratado o problema de roteirização trata-se de um problema np-hard, com grande complexidade de resolução, devido ao rápido crescimento fatorial. Diante disso, e da necessidade de gerar as rotas para o planejamento tático-operacional, o modelo proposto utilizou a metaheurística reconhecida da Busca Tabu.

Com vistas a proposição de um modelo integrado, utilizou-se o software de código aberto OR-Tools, uma biblioteca de ferramentas de pesquisa operacional, desenvolvida pela Google, “para otimização, ajustado para lidar com os problemas mais difíceis do mundo em roteamento de veículos, fluxos, programação inteira e linear e programação com restrições” (VAN OMME *et al*, 2014; GOOGLE, 2021).

Assim, utilizou-se a biblioteca *Routing* do OR-Tools, em um código em Python, realizando a integração com a ferramenta Gmaps, a fim de gerar a distância e o tempo de deslocamento entre os pontos conforme a utilização das vias públicas, permitindo a proposição da utilização do modelo na prática por viaturas policiais. No caso, considerando o tempo máximo do turno de serviço, utilizar-se a um modelo de janelas de tempo, de acordo com a seguinte formulação:

$$f(x) = \text{Min} \sum_{k \in K} \sum_{i \in V} \sum_{j \in V} t_{ij} x_{ijk} \quad (\text{Equação 23})$$

Sujeito a:

$$\sum_{k \in K} \sum_{j \in V} x_{ijk} = 1, \forall i \in P \quad (\text{Equação 24})$$

$$\sum_{i \in V} x_{ihk} - \sum_{j \in V} x_{hjk} = 0, \forall k \in K, \forall h \in P \quad (\text{Equação 25})$$

$$\sum_{k \in K} x_{0jk} \leq 1, \forall j \in P \quad (\text{Equação 26})$$

$$\sum_{k \in K} x_{ijk} \leq q, \forall i \in P, \forall j \in V \quad (\text{Equação 27})$$

$$y_{ik} + s_i + t_{ij} - y_{jk} + M x_{ijk} \leq M, \forall i \in V, \forall j \in P, k \in K \quad (\text{Equação 28})$$

$$y_{ik} + s_i + t_{i0} + T + M x_{i0k} \leq M, \forall i \in P, k \in K \quad (\text{Equação 29})$$

$$a_i \leq y_{ik} \leq b_i, \forall k \in K, \forall i \in V \quad (\text{Equação 30})$$

$$x_{ijk} \in \{0,1\}, \forall i, j \in V, \forall k \in K, i \neq j \quad (\text{Equação 31})$$

$$y_{ik} \in R_+, \forall k \in K, \forall i \in V - \{0\} \quad (\text{Equação 32})$$

Onde,

- $V = \{0,1,2,\dots,n\}$: conjunto de vértices, compreendendo a sede do batalhão(0) e os pontos-base das viaturas;
- $P = \{1,2,\dots,n\}$: conjunto de pontos-base das viaturas;
- $K = \{1,2,\dots,m\}$: conjunto de rotas ou viaturas que executarão cada rota;
- t_{ij} : tempo gasto no deslocamento no trecho compreendido entre i e $j, \forall i, j \in V$;
- T : tempo máximo de duração para a realização do roteiro;
- q : capacidade máxima de atendimento de cada viatura;
- s_i : tempo de serviço para o atendimento do ponto $i, \forall i \in P$;
- $[a_i, b_i]$: intervalo (janela de) de tempo na qual o ponto i deve ser visitado;
- x_{ijk} : variável binária que assume o valor 1, caso o ponto j seja visitado após o ponto i ;
- y_{ik} : variável real não negativa que indica os tempos de deslocamento e serviço acumulados até a parada no ponto i ;
- M : constante.

Observa-se que a função objetivo compreende minimizar o custo de tempo de realização de todas as rotas para atendimento dos pontos-base (Equação 23). As restrições referem-se respectivamente: ao atendimento de todos os pontos-base com uma rota realizada (Equação 24); a conservação de fluxo da rota (Equação 25); a necessidade de que cada rota/viatura saia da sede do batalhão no máximo uma vez (Equação 26); o respeito a capacidade máxima de atendimentos dos pontos pela viatura (Equação 27); o atendimento da janela de

tempo considerando os tempos de deslocamentos e de serviço acumulados (Equação 28); o atendimento da janela de tempo e tempo máximo do turno de serviço da viatura no retorno ao batalhão (Equação 29); o enquadramento do tempo acumulado no momento de parada no ponto-base, de acordo com os limites de tempo inferior e superior (Equação 30). Por fim, as restrições tratam da definição das variáveis x como inteiras e binárias, e das variáveis y como reais positivas.

3.4.1 Parâmetros

Conforme a definição do problema de roteirização de veículos clássico parte-se de um local de saída dos veículos que devem atender determinados pontos (clientes) e retornar ao local de origem com o menor custo. Tratando-se de roteirização de patrulha policiais as viaturas (patrulhas) deslocam do efetivo da unidade operacional (no caso da sede do batalhão), para o qual deverão retornar ao término do turno, após realizar o patrulhamento e a permanência em locais com o foco de prevenção da criminalidade.

No estudo proposto, trata-se da realização de patrulhamento e alocação com vistas a prevenção de homicídios na área de ação do batalhão, sendo que o ponto de origem é o próprio batalhão e os pontos de cobertura (“clientes”) são os locais com maior risco de ocorrências, no caso definidos utilizando-se o RTM, considerando 34 ou 17 pontos para cada mês de planejamento.

Ainda, necessita-se definir como parâmetro o tempo máximo do turno do serviço para definir a janela de tempo de atuação nos pontos e retorno à origem. Assim, considerando os dados estatísticos já apresentados, nota-se que mais de 60% dos fatos ocorreram no período de 8 horas (das 17h até 1h). Logo, a fim de tratar da realização de ações intermitentes nos pontos como propõe Koper (1995), definiu-se num primeiro modelo o tempo de 4 h como tempo de atendimento máximo da rota, e após o período de 2h como tempo máximo da rota, permitindo a reiteração de atividades nos locais de risco, no período de 8h de serviço.

Por fim, resta a definição do parâmetro de tempo de serviço nos pontos de parada, outra vez se seguirá o reconhecido estudo de Koper, que indica um período mínimo de 10 minutos a 20 minutos, indicando como ideal 15 minutos. Diante disso, para o modelo de 4 horas, no qual haverá uma menor quantidade de visitas, utilizou-se 20 minutos e para o modelo de 2 horas, com o objetivo de aumentar o dinamismo, utilizou-se a medida de 15 minutos.

3.4.2 Heurísticas utilizadas

Como apontado o problema de roteamento é de modo inerente de difícil resolução diante do aumento exponencial necessário para a sua resolução. Diante disso, o *OR-Tools Routing* disponibiliza metaheurísticas para a resolução dos problemas modelados.

No presente trabalho, optou-se pela utilização da metaheurística Busca Tabu (Tabu Search), após a solução inicial elaborada a partir de uma heurística de vizinho mais próximo (na biblioteca identificada como *path cheapest arc* (caminho com arco de menor custo). A descrição da heurística indica que “a partir de um nó "inicial" de rota, conecte-o ao nó que com o menor custo na rota e, em seguida, estende a rota iterando no último nó adicionado à rota” (GOOGLE, 2021).

Na sequência, foi programada como metaheurística a Busca Tabu, dentre as opções disponíveis, diante da reconhecida adequação a situações práticas como referenciado.

Como não há a utilização desse modelo de roteirização na prática, e considerando que caso os planejamentos não sejam realizados de forma totalmente aleatória, os modelos foram rodados com a solução inicial, proposta possível de ser elaborada por um gestor, considerando sempre o ponto mais próximo do último visitado, até o alcance das restrições de tempo, com as soluções produzidas com a utilização da Busca Tabu.

Tal comparação, se deve justamente a partir da ausência de uma referência, sendo que se comparará para cada rota uma solução viável e boa (*path cheapest arc*) com uma solução melhorada (*Tabu Search*), a fim de demonstrar a possibilidade de melhoria, da utilização de um modelo com uma boa metaheurística, resultando na possibilidade de redução de recursos e custos, para realização da mesma atividade.

Ademais, a aplicação integrou com o app Google Maps para gerar os mapas finais das rotas, produzindo material passível de utilização prática das patrulhas ou integração em outro aplicativo da instituição.

4 RESULTADOS E ANÁLISE

4.1 Modelo de localização de patrulhas

Como apresentado, a primeira fase do modelo de policiamento inteligente, envolve a localização das patrulhas policiais, sendo que foram testados quatro modelos para análise e comparação quanto a possibilidade de predição, ou seja, posicionamento nos locais em que possivelmente ocorreriam os homicídios na área de estudo. Recapitulando foram utilizados um método preditivo de risco terreno (RTM), um método de clusterização (k-means), um método de localização de facilidades (p-medianas) e um método de localização com máxima cobertura (MCLP).

Destaca-se que a análise enfatizou, especialmente, a capacidade de predição, considerando os pontos indicados por cada um dos métodos para cada mês de estudo e a ocorrência de homicídios nas áreas aproximadas destes pontos.

Conforme a indicação do método RTM, de que os grids de altíssimo risco corresponderam a 5% da área e de alto e altíssimo risco a 10% da área, e considerando que nos demais métodos deve-se indicar o número de pontos a serem definidos, foram utilizados respectivamente a indicação de 17 e 34 pontos para cada período (mês) de estudo. Dessa forma, no RTM definiu-se a quantidade definida de grids e após a definição de seus centros e nos demais métodos a quantidade de pontos foi definida estipulando-se uma área de influência para fins de comparação.

Destaca-se que no RTM, foram utilizados grids de 500m X 500m, ou seja, células de 0,25 Km², a fim de permitir uma melhor comparação, a partir dos pontos definidos nos demais métodos foi delimitada uma área ao redor do ponto com um raio de 300m, chegando-se para cada ponto em uma área de influência de 0,28 Km².

Os quadros a seguir apresentam os resultados de cada método considerando as duas quantidades do parâmetro de quantidade de pontos definida.

Observando a tabela 5, nota-se que o modelo utilizando o RTM no geral apresentou melhores resultados, em comparação com os demais métodos, sendo que 43% dos homicídios no período de janeiro de 2020 a junho de 2021 ocorreram nas áreas identificadas de maior risco, ocorrendo no interior dos 34 grids definidos para cada mês de análise como proposta de localização de patrulhas policiais. Na melhor das expectativas, poderia se considerar que até 102 ocorrências de homicídios (consumados ou tentados) entre 238 ocorridos poderiam ser prevenidos se as ações policiais tivessem focado nos pontos indicados através do modelo

preditivo. Na sequência, os dados apresentam que 39% dos homicídios ocorreram no raio de 300m dos pontos definidos pelo método das p-medianas, 37% utilizando-se o MCLP e 30% através do k-means.

Tabela 5 - Comparação de acertos nas áreas de influência de 34 pontos definidos por mês, conforme cada método de localização

Método		Kmeans		MCLP		P-Mediana		RTM	
Mês	Oc.	Acertos	Percentual	Acertos	Percentual	Acertos	Percentual	Acertos	Percentual
jan/20	13	3	23%	4	31%	5	38%	4	31%
fev/20	14	7	50%	5	36%	4	29%	5	36%
mar/20	11	3	27%	6	55%	8	73%	6	55%
abr/20	11	3	27%	1	9%	3	27%	4	36%
mai/20	25	4	16%	6	24%	6	24%	8	32%
jun/20	9	6	67%	6	67%	7	78%	6	67%
jul/20	16	6	38%	6	38%	6	38%	9	56%
ago/20	7	2	29%	5	71%	4	57%	4	57%
set/20	11	2	18%	5	45%	2	18%	3	27%
out/20	10	5	50%	2	20%	3	30%	4	40%
nov/20	15	4	27%	4	27%	6	40%	8	53%
dez/20	13	4	31%	5	38%	7	54%	6	46%
jan/21	19	5	26%	8	42%	9	47%	8	42%
fev/21	8	2	25%	3	38%	6	75%	3	38%
mar/21	8	2	25%	3	38%	1	13%	4	50%
abr/21	15	4	27%	5	33%	5	33%	7	47%
mai/21	17	5	29%	6	35%	5	29%	9	53%
jun/21	16	5	31%	8	50%	6	38%	4	25%
Total	238	72	30%	88	37%	93	39%	102	43%

Fonte: elaborado pelo autor

Cabe destacar que embora os resultados do RTM tenham se mostrado melhores, a utilização dos outros métodos demonstra índices consideráveis de assertividade, caso sejam priorizados somente 34 pontos em toda área de estudo, cerca de 10% de toda a extensão de responsabilidade territorial.

Considerando uma quantidade mais reduzida de pontos (Tabela 6), e no caso do RTM com maior grau de risco, nota-se que 31% dos homicídios no período de estudo ocorreram dentro dos grids que representavam 5% da área de estudo, também apresentando o melhor resultado comparado com outros métodos. Destaca-se também a assertividade do método de máxima cobertura, com o número reduzido de pontos, sendo que um quarto das ocorrências dos crimes foram na área de cobertura indicada.

Tabela 6 - Comparação de acertos nas áreas de influência de 17 pontos definidos por mês, conforme cada método de localização

Método		Kmeans		MCLP		P-Mediana		RTM	
Mês	Oc	Acertos	Percentual	Acertos	Percentual	Acertos	Percentual	Acertos	Percentual
jan/20	13	2	15%	0	0%	1	8%	2	15%
fev/20	14	0	0%	4	29%	0	0%	5	36%
mar/20	11	1	9%	3	27%	3	27%	4	36%
abr/20	11	2	18%	1	9%	1	9%	3	27%
mai/20	25	2	8%	5	20%	5	20%	3	12%
jun/20	9	2	22%	6	67%	6	67%	4	44%
jul/20	16	2	13%	5	31%	3	19%	6	38%
ago/20	7	0	0%	2	29%	0	0%	1	14%
set/20	11	1	9%	4	36%	1	9%	3	27%
out/20	10	4	40%	2	20%	0	0%	4	40%
nov/20	15	4	27%	5	33%	5	33%	6	40%
dez/20	13	5	38%	3	23%	1	8%	4	31%
jan/21	19	3	16%	5	26%	3	16%	7	37%
fev/21	8	0	0%	2	25%	0	0%	3	38%
mar/21	8	2	25%	2	25%	0	0%	2	25%
abr/21	15	1	7%	2	13%	5	33%	6	47%
mai/21	17	6	35%	6	35%	4	24%	8	47%
jun/21	16	3	19%	4	25%	4	25%	3	19%
Total	238	40	17%	61	26%	42	18%	74	31%

Fonte: elaborado pelo autor

A tabela 7 demonstra uma síntese do percentual de acertos no total do período de cada um dos métodos:

Tabela 7 - Percentual de acerto de ocorrências de homicídios por método, no período (jan/20 a jun/21)

Método	Kmeans	MCLP	P-mediana	RTM
34 pontos	30%	37%	39%	43%
17 pontos	17%	26%	18%	31%

Fonte: elaborado pelo autor

Ainda, se propõe uma análise com base no índice de cada mês, considerando que o número de fatos criminais variou ao longo do período de 7 a 25 incidentes no mês. Assim, o quadro a seguir estabelece a média e o desvio padrão considerando os índices de cada período.

Tabela 8 - Média de percentual de acerto mês a mês por método (jan/20 a jun/21)

Modelo\Método	Kmeans	MCLP	P-medianas	RTM
34 pontos	31,4%	38,7%	41,1%	43,9%
DV 34 pontos	12,5%	15,3%	19,2%	11,7%
17 pontos	16,7%	26,3%	16,5%	31,5%
DV 17 pontos	12,6%	13,6%	17,1%	10,7%


Fonte: elaborado pelo autor. DV (Desvio Padrão)

O quadro apresenta dados relevantes, sendo que na média dos índices de cada mês o RTM mantém os melhores resultados quanto a predição dos fatos. Outro fato importante, trata-se justamente no fato de apresentar maiores índices de acerto e menores desvios-padrão, comparando-se com os demais métodos. Dessa forma, os índices dos modelos utilizando o RTM apresentam menor variação.

Logo, pode-se indicar que o modelo possibilita indicar que em cada mês cerca de 43,9% das ocorrências serão nas áreas indicadas, para 34 pontos, com um desvio-padrão de 11,7%, e aproximadamente 31,5% ocorrerão nos grids selecionados, para 17 pontos, com desvio-padrão de 10,7%. Observa-se, a partir boxplots (figuras 26 e 27) que os resultados do RTM não apresentam outliers, além de menor variação e concentração de resultados maiores do que nos demais métodos.

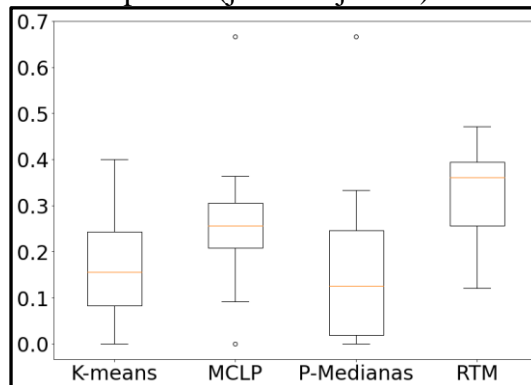
Cumprir destacar que o modelo utilizado de RTM apresentou resultado de acerto semelhante ao encontrado no estudo de meta-análise em pesquisas com a utilização do modelo, realizado por Marchment e Gill (2021), no qual aferiram uma precisão de cerca de 44,7% de eventos ocorridos em 10% das células avaliadas, classificadas como de alto risco. No presente estudo, a precisão foi de 43%, considerando 10% da área, devendo-se salientar que o utilizando-se a proporção de grids, os 34 pontos utilizados representam 8,5% dos grids definidos.

Figura 26 - Boxplot com os índices de acertos dos diferentes métodos para a definição de 34 pontos (jan/20 a jun/21)



Fonte: elaborado pelo autor.

Figura 27 - Boxplot com os índices de acertos dos diferentes métodos para a definição de 17 pontos (jan/20 a jun/21)



Fonte: elaborado pelo autor.

Além do mais, deve se esclarecer que o modelo considerou dados de um trimestre para a proposição de ocorrências em um mês de análise, diferente dos estudos realizados anteriormente que a partir de dados semestrais ou anuais estabeleciam a previsão para período de tempos semelhantes.

Nota-se evidente que no aspecto de previsão o RTM apresenta melhores índices, sendo então incorporado como referência de localização, através dos centros dos grids para a 2ª fase do modelo de policiamento inteligente: a roteirização.

4.2 Modelo de roteirização de patrulhas

A segunda fase do modelo de planejamento tático-operacional das ações de patrulhamento e permanência em locais de risco de homicídios inicia, justamente, com a identificação dos pontos de atuação (locais de maior risco) identificados através da modelagem de risco terreno e a consequente roteirização das viaturas nesses pontos partindo do batalhão.

Como exposto foram geradas as rotas das viaturas para cada um dos seis meses de análise do ano de 2021, sendo o primeiro modelo para um turno máximo de 4 horas para cada viatura com tempo de parada em cada um dos pontos de 20 minutos.

Essa primeira proposta considerou a apresentação de 34 pontos de risco e 17 pontos de risco, da forma já tratada anteriormente, sendo que foram geradas as rotas a partir de uma heurística gulosa de vizinho mais próximo (a fim de aproximar da definição de rotas realizadas pelos gestores sem uso de ferramenta, diante da simplicidade do algoritmo) e a roteirização utilizando a Busca Tabu.

Importante destacar que o objetivo da aplicação é realizar a prevenção nos pontos, logo através das rotas com menor custo (tempo ou distância) haverá a possibilidade de cobertura com menos recursos e custos.

Tabela 8 - Quadro comparativo de rotas para 34 pontos de risco (RTM), utilizando Algoritmo Greedy e Busca Tabu (turnos de 4h, 20 min de parada).

Mês	Vizinho mais próximo (Greedy - Path Cheapest Arc - PCA)				Busca Tabu (Tabu Search - TS)			
	Tempo Total	Tempo de desloc.	Qtde Vtr	Distância Total (km)	Tempo Total	Tempo de desloc.	Qtde Vtr	Distância Total (km)
jan/21	16:11:15	04:51:15	5	132,3	15:11:09	03:51:09	4	100,1
fev/21	15:31:03	04:11:03	5	104,9	14:52:20	03:32:20	4	89,6
mar/21	15:14:14	03:54:14	4	96,6	14:44:38	03:24:38	4	82,0
abr/21	15:26:42	04:06:42	4	99,2	14:44:18	03:24:18	4	81,5
mai/21	16:13:48	04:53:48	5	120,3	14:56:21	03:36:21	4	83,9
jun/21	15:27:03	04:07:03	4	103,3	14:50:31	03:30:31	4	86,1
Média	15:40:41	04:20:41	4,5	109,4	14:53:13	03:33:13	4	87,2

Fonte: elaborado pelo autor

Tabela 9 - Quadro de redução de tempo de deslocamento e distância de rotas para 34 pontos de risco (RTM), utilizando Algoritmo Greedy e Busca Tabu (turnos de 4h, 20 min de parada).

Mês	Redução de tempo de deslocamento (PCA-TS)		Redução de distância (PCA-TS)	
	Percentual (%)	Total (hh:mm:ss)	Percentual (%)	Total (Km)
jan/21	20,6%	01:00:06	24,3%	32,1
fev/21	15,4%	00:38:43	14,5%	15,2
mar/21	12,6%	00:29:36	15,1%	14,6
abr/21	17,2%	00:42:24	17,8%	17,7
mai/21	26,4%	01:17:27	30,3%	36,4
jun/21	14,8%	00:36:32	16,6%	17,1
Média	17,8%	00:47:28	19,8%	22,2

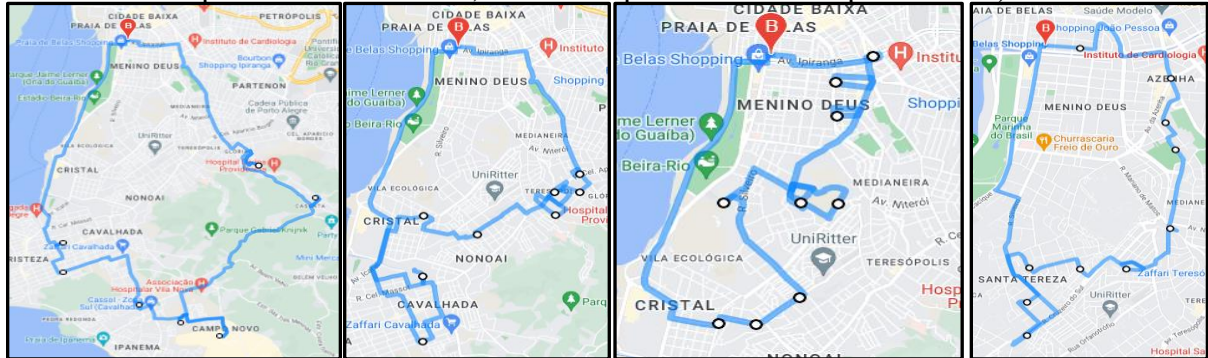
Fonte: elaborado pelo autor

Observando os quadros nota-se que as rotas geradas utilizando Busca Tabu mostraram-se muito mais eficientes do que as organizadas utilizando a heurística gulosa do vizinho mais próximo (simulando um planejamento sem ferramenta). O primeiro aspecto relevante é que enquanto nas rotas de Busca Tabu, em todos os seis meses, considerando os 34 pontos a serem atendidos em cada período, foram necessárias 4 viaturas /rotas para a cobertura de todos os pontos, na heurística gulosa em metade dos meses foi necessário acrescentar uma rota ou, não havendo recurso, alguns pontos ficariam descobertos.

Ainda, as rotas com Busca Tabu reduziram o tempo total de deslocamento, para cada período de planejamento de 47 minutos e 28 segundos, além de apresentar uma redução de 22,2 km de distância percorrida, para cada vez que as rotas fossem cumpridas, representando uma

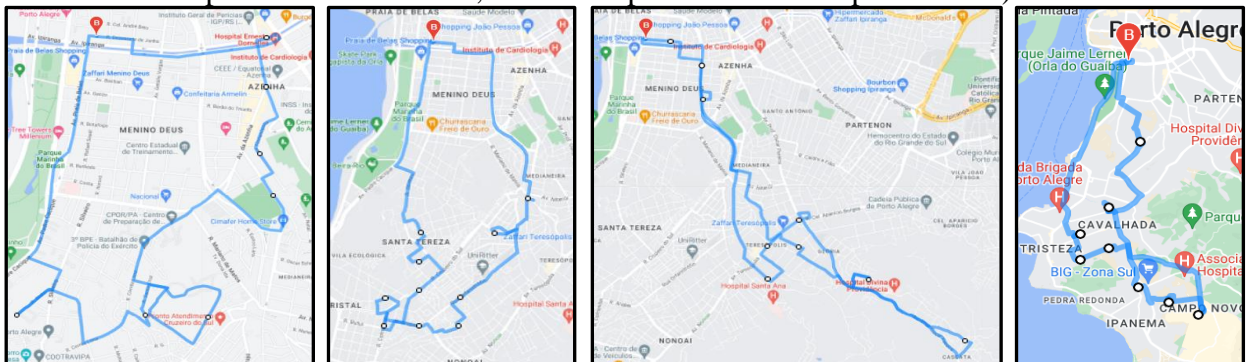
redução de 17,8% do tempo e 19,8% na distância percorrida (questão que reflete nos custos com combustível e manutenção dos veículos). Cabe destacar que do tempo total das rotas 11 horas e 20 minutos.

Figura 28 - Mapas com rotas produzidas para o mês de abril de 2021 – Path Cheapest Arc (34 pontos - turnos de 4h, 20 min de permanência nos pontos base)



Fonte: elaborado pelo autor

Figura 29 - Mapas com rotas produzidas para o mês de abril de 2021 – Busca Tabu (34 pontos - turnos de 4h, 20 min de permanência nos pontos base)



Fonte: elaborado pelo autor

Tabela 10 - Quadro comparativo de rotas para 17 pontos de risco (RTM), utilizando Algoritmo Greedy e Busca Tabu (turnos de 4h, 20 min de parada)

Mês	Vizinho mais próximo (Greedy - Path Cheapest Arc - PCA)				Busca Tabu (Tabu Search – TS)			
	Tempo Total	Tempo de desloc.	Qtde Vtr	Distância Total (km)	Tempo Total	Tempo de desloc.	Qtde Vtr	Distância Total (km)
jan/21	08:13:02	02:33:02	3	66,3	07:28:50	01:48:50	2	47,1
fev/21	08:21:23	02:41:23	3	68,3	07:49:36	02:09:36	2	55,1
mar/21	08:07:52	02:27:52	3	62,5	07:27:36	01:47:36	2	46,2
abr/21	08:24:19	02:44:19	3	67,1	07:32:58	01:52:58	2	45,2
mai/21	08:24:41	02:44:41	3	68,8	07:31:03	01:51:03	2	44,0
jun/21	08:07:26	02:27:26	3	60,8	07:40:06	02:00:06	2	48,5
Média	08:16:27	02:36:27	3	65,6	07:35:01	01:55:01	2	47,7

Fonte: elaborado pelo autor

Tabela 11 - Quadro de redução de tempo de deslocamento e distância de rotas para 17 pontos de risco (RTM), utilizando Algoritmo Greedy e Busca Tabu (turnos de 4h, 20 min de parada).

Mês	Redução de tempo de deslocamento (PCA-TS)		Redução de distância (PCA-TS)	
	Percentual (%)	Total (hh:mm:ss)	Percentual (%)	Total (Km)
jan/21	28,9%	00:44:12	28,9%	19,1
fev/21	19,7%	00:31:47	19,3%	13,1
mar/21	27,2%	00:40:16	26,2%	16,4
abr/21	31,3%	00:51:21	32,6%	21,9
mai/21	32,6%	00:53:38	36,0%	24,8
jun/21	18,5%	00:27:20	20,3%	12,3
Média	26,4%	00:41:26	27,2%	17,9

Fonte: elaborado pelo autor.

Tratando-se do modelo com menos pontos a serem cobertos, na proporção, a redução mostrou-se ainda mais significativa. Assim, na comparação as rotas utilizando a Busca Tabu (BT) apresentaram-se, em média, 26,4% mais rápidas (menor tempo, reduzindo em média 41 minutos) e 27,2% mais curtas (cerca de 17,9km menos distantes).

Ademais, enquanto no modelo com BT em todos os meses 2 rotas seriam necessárias para cobrir todos os pontos de altíssimo risco, com a heurística do vizinho mais próxima utilizada, duas rotas não seriam suficientes para o atendimento completo dos locais indicados. Aqui também deve-se considerar um tempo total de permanência nos pontos-base (locais de parada) das viaturas: 5 horas e 40 minutos (20 minutos em cada um dos 17 locais).

A fim de verificar se a melhora seria significativa em modelos com outros parâmetros, priorizando o 5% da área como propõe Weisburd (2015), e considerando a dinâmica proposta por Koper (rondas intermitentes tempo máximo da rota de 2 horas, com tempo ideal de parada de 15 minutos), foram geradas novas roteirização para os 17 pontos identificados para cada um dos seis meses de análise do ano de 2021.

Embora nesse formato, com as duas soluções a mesma quantidade de recursos (4) seriam suficientes para cobrir todos os pontos-base, observa-se que a redução ainda é relevante. Sendo que estando disponíveis quatro guarnições para essa atividade as quatro rotas em um serviço de 8 h, poderiam ser realizadas quatro vezes, sendo que a solução com Busca Tabu geraria em média uma redução de 46km de deslocamento em cada dia de execução.

Tabela 12 - Quadro comparativo de rotas para 17 pontos de risco (RTM), utilizando Algoritmo Greedy e Busca Tabu (turnos de 2h, 15 min de parada).

Mês	Vizinho mais próximo (Greedy - Path Cheapest Arc - PCA)				Busca Tabu (Tabu Search - TS)			
	Tempo Total	Tempo de desloc.	Qtde Vtr	Distância Total (km)	Tempo Total	Tempo de desloc.	Qtde Vtr	Distância Total (km)
jan/21	07:16:41	03:01:41	4	83,8	06:45:53	02:30:53	4	67,5
fev/21	07:18:00	03:03:00	4	80,0	07:05:27	02:50:27	4	76,6
mar/21	07:05:08	02:50:08	4	75,4	06:40:39	02:25:39	4	62,7
abr/21	07:13:03	02:58:03	4	75,7	06:35:14	02:20:14	4	56,8
mai/21	06:56:49	02:41:49	4	68,0	06:41:46	02:26:46	4	61,8
jun/21	07:10:54	02:55:54	4	78,7	06:51:01	02:36:01	4	67,0
Média	07:10:06	02:55:06	4	76,9	06:46:40	02:31:40	4	65,4

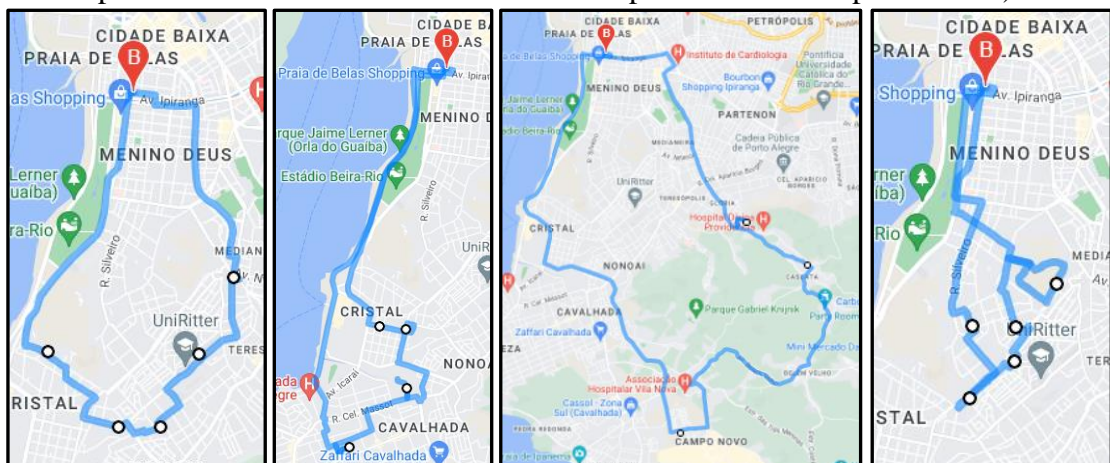
Fonte: elaborado pelo autor

Tabela 13 - Quadro de redução de tempo de deslocamento e distância de rotas para 17 pontos de risco (RTM), utilizando Algoritmo Greedy e Busca Tabu (turnos de 2h, 15 min de parada).

Mês	Redução de tempo de deslocamento (PCA-TS)		Redução de distância (PCA-TS)	
	Percentual (%)	Total (hh:mm:ss)	Percentual (%)	Total (Km)
jan/21	17,0%	00:30:48	19,5%	16,3
fev/21	6,9%	00:12:33	4,3%	3,4
mar/21	14,4%	00:24:29	16,8%	12,6
abr/21	21,2%	00:37:49	25,0%	18,9
mai/21	9,3%	00:15:03	9,2%	6,3
jun/21	11,3%	00:19:53	14,8%	11,6
Média	13,3%	00:23:26	14,9%	11,5

Fonte: elaborado pelo autor.

Figura 30 - Mapas com rotas produzidas para o mês de fevereiro de 2021 – Busca Tabu (17 pontos - turnos de 2h com 15 minutos de permanência nos pontos base).



Fonte: elaborado pelo autor.

Referente ao tempo de execução, em um computador Intel core i7 da 11ª Geração, enquanto as rotas usando a heurística gulosa tenha rodado em média 0,019s, as rotas com Busca Tabu foram geradas em média em 8,45s, em ambos os casos já tendo gerado a matriz de distâncias com aplicação integrada do Google, para os modelos com 17 pontos.

Para os modelos com 34 pontos os modelos com a heurística *path cheapest arc* apresentaram os resultados em média em 0,162s, já os modelos com BT mostraram os resultados em média em 24s. Além disso, a matriz de distância utilizando a aplicação de distância de deslocamentos por vias públicas foi gerada, em média em 5 minutos e 31 segundos, sendo gerada uma vez para cada mês de análise.

Por fim, embora o reconhecimento de tratar-se de um problema np-hard, como já tratado realizou-se testes de algumas instâncias, com os últimos parâmetros apresentados (17 pontos, turno de 2h e tempo de parada de 15 minutos), utilizando o solucionador CPLEX, a partir da programação do problema (conforme equações de 23 a 32), utilizando o modelador Pulp em Python, buscando uma solução exata.

Não tendo apresentado a resolução após rodar durante 6 dias, utilizou-se o limite de tempo para rodar as instâncias de janeiro, fevereiro e março de 2021, com o tempo limite de 24 horas (86400 segundos), sendo alcançados os resultados a seguir apresentados, salienta-se que o resultado apresentado no limite de tempo como ótimo, segundo a documentação do modelador trata-se do melhor resultado viável durante o período de execução definido:

Tabela 13 - Quadro comparativo de rotas para 17 pontos de risco (RTM), utilizando Cplex e Busca Tabu (turnos de 2h, 15 min de parada).

Mês	Cplex (Pulp/Python)				Busca Tabu (Tabu Search – TS)				Redução (TS/Cplex)
	Tempo Total	Tempo de desloc.	Qtde Vtr	Tempo exec. (s)	Tempo Total	Tempo de desloc.	Qtde Vtr	Tempo exec. (s)	%
jan/21	06:44:15	02:29:15	4	86472	06:45:53	02:30:53	4	8,02	1,1
fev/21	07:04:07	02:49:07	4	86501	07:05:27	02:50:27	4	9,27	0,8
mar/21	07:05:08	02:25:39	4	86500	06:40:39	02:25:39	4	8,58	0,0
Média	07:10:06	02:55:06	4	86491	06:46:39	02:31:39	4	8,62	0,63

Fonte: elaborado pelo autor.

A partir do teste realizado percebe-se que o melhor resultado, apresentado a partir de uma formulação para encontrar a solução exata, após cerca de 24 horas de execução foi em média 0,63% melhor que a aplicação utilizando a Busca Tabu, sendo que a maior diferença foi de 1,1%. No entanto, o tempo de execução do Busca Tabu para encontrar resultados

semelhantes foi mais de dez mil vezes menor, justificando-se a utilização da heurística para a solução do problema.

Por fim, observando os resultados (mapas com as rotas), elaborados através da Busca Tabu, verifica-se que são plenamente executáveis, na prática, verificando-se que a utilização de uma técnica mais aperfeiçoada de busca local, permite melhores soluções do que uma solução gerada com uma heurística mais simples, e da mesma forma se fosse comparada com rotas produzidas aleatoriamente, sem a utilização de ferramentas ou aplicações.

4.3 Modelo integrado

Após a demonstrações dos resultados dos modelos de alocação e roteirização, considerando o objetivo da pesquisa operacional de proporcionar ferramentas e sistemas para a construção de modelos de para a tomada de decisão, encontrando as melhores soluções na tentativa de resolver os problemas (JENSEN, BARD, 2003), buscou-se apresentar um modelo de policiamento inteligente integrado: um Modelo Preditivo de Localização e Roteirização de Patrulhas (MPLRP).

Destaca-se que a proposição seguiu o processo de resolução de problemas de pesquisa operacional (RAGSDALE, 2009; LACHTERMACHER, 2018), seguindo suas cinco etapas essenciais e consecutivas:

1º) Identificação do Problema: propor um planejamento tático operacional para prevenção de homicídios na área de estudo.

2º) Formulação e implementação do modelo: Modelo proposto em duas fases, a primeira de localização das patrulhas em locais de maior risco de ocorrências de homicídios (com base no RTM) e a segunda de roteirização de patrulhas (com a heurística da Busca Tabu).

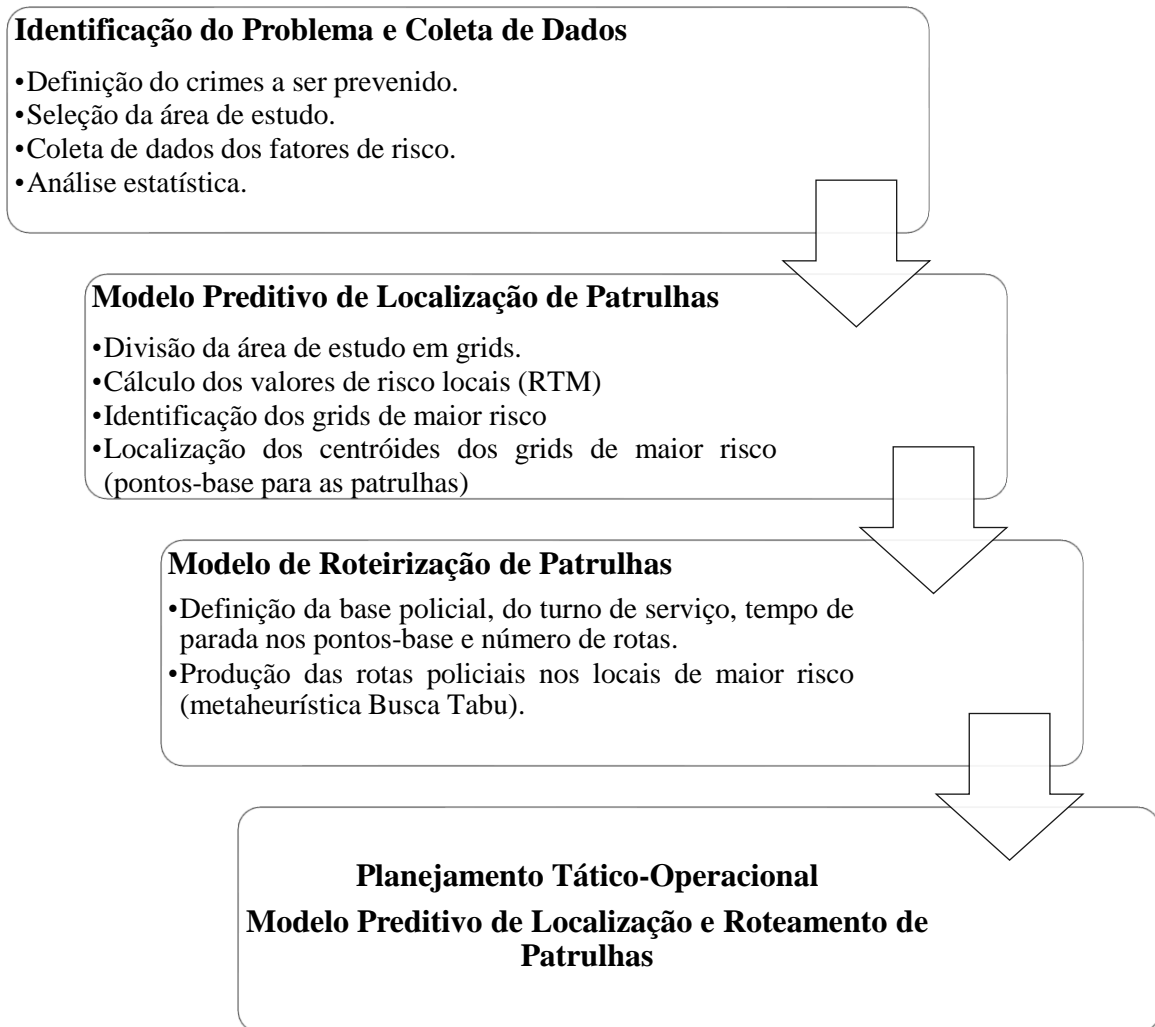
3º) Análise do modelo: os modelos foram analisados de forma comparativa. A localização de patrulhas demonstrou melhores resultados de assertividade (predição) nos locais indicados, considerando o emprego do método a indicação de locais de risco para cada mês de análise, durante 18 meses (janeiro de 2020 a junho de 2021), com a localização das ocorrências de homicídios de cada um dos meses. Quanto a roteirização a avaliação considerou a comparação do modelo utilizando a metaheurística da Busca Tabu com a roteirização realizada a partir da heurística gulosa de vizinho mais próxima, método que se aproxima de uma forma de pensar natural do tomador de decisão.

4º) Teste dos resultados: Foram realizados diversos testes considerando diferentes métodos, a fim de aferir o modelo proposto, como demonstrado nas seções anteriores.

5º) Implementação da solução e monitoração: considerando a utilização de dados reais, verifica-se que há possibilidade de implantação do modelo na rotina das atividades policiais.

Assim, o MPLRP pode ser sintetizado da forma da figura 31.

Figura 31 - Fluxograma do Modelo Preditivo de Localização e Roteirização de Patrulhas.



Fonte: elaborado pelo autor.

Portanto, como qualquer processo de tomada de decisão o modelo decorre da definição do problema, com a seleção do crime ou fato de ofensa à ordem pública que se pretende prevenir, bem como a área de atuação, com a consequente coleta dos dados e análise estatística prévia para definição de parâmetros.

Após inicia-se a etapa do Modelo Preditivo de Localização de Patrulhas, utilizando-se um modelo baseado no RTM, considerando a aplicação para cada período, segundo os dados dos fatores de risco, gerando a identificação dos grids com maior risco criminal. A partir da seleção dos grids de alto risco, localiza-se os centróides para a designação dos pontos-base para

atividade de permanência das patrulhas, considerando a prevenção criminal pelas ações de presença.

A partir da seleção dos pontos, estes serão os dados de entrada, juntamente com a localização da sede policial, e dos parâmetros de tempo máximo para a execução das rotas, tempo de parada nos pontos-base e quantidade de rotas a serem executadas ou viaturas disponíveis. Após tais definições, a aplicação, considerando dados reais de custo de deslocamentos dentre os pontos, a partir de app integrado Google Maps, produz a roteirização nos pontos de maior risco de incidência do crime .

Dessa forma, a partir de dados dos fatores de risco produz-se o planejamento tático-operacional integrado com a localização e roteirização das viaturas para atender o objetivo proposto.

5 CONSIDERAÇÕES FINAIS

Como exposto o tema de segurança pública é fundamental para a vida em sociedade, tratando-se de questão complexa, envolvendo diversos fatores, os quais, se não controlados, conduzem a ocorrências de crimes a partir da disposição de autores em delinquir, a existência de vítimas e de ambientes propícios a ocorrência dos crimes.

Com este mote, as ações de planejamento dos gestores policiais devem definir as estratégias policiais acertadas para a prevenção de ocorrências, a partir de medidas proativas, considerando o uso correto dos dados, a partir do aperfeiçoamento analítico, definição e acompanhamento de metas e estímulo a ações inovadoras. Ou seja, devem ajustar o processo de tomada de decisões para que estas seja cada vez mais eficiente e eficaz, partindo o melhor emprego possível dos recursos, os quais, em geral tratando-se de segurança pública, têm se mostrado escassos e, muitas vezes, insuficientes para o cumprimento de todas as medidas necessárias.

Diante dessa necessidade, especialmente nos atos de gestão e planejamento, a utilização de métodos e ferramentas para aprimorar o policiamento ostensivo preventivo em locais de risco, fundamentados em medidas de polícia inteligente, surgem como alternativa inovadora e necessária, quando a quantidade de dados disponíveis cada vez mais é incrementada, porém a forma de planejamento permanece a mesma a décadas.

Nesse contexto foi proposto um modelo de policiamento inteligente integrado, Modelo Preditivo de Localização e Roteamento de Patrulhas, para melhor emprego de viaturas policiais com vistas a redução criminal. Com este mote, o trabalho considerou dados da área de ação de um Batalhão de Polícia Militar no município de Porto Alegre, com foco na análise no crime de homicídio.

A partir de uma revisão sobre policiamento inteligente e preditivo, verificou-se que a temática pode ser muito desenvolvida, principalmente, em nosso país, considerando que estudos específicos sobre a temática, surgiram a pouco mais de uma década. Contudo, já existe um portfólio considerável de métodos, modelos e ferramentas que têm apresentado excelentes resultados, com a possibilidade de aplicação, ajustando os parâmetros e variáveis as realidades de cada ambiente.

Com base, nos trabalhos pesquisados, se vislumbrou a oportunidade de desenvolvimento de modelo integrado para localizar as viaturas na área de estudo (área para desenvolvimento das ações operacionais), em locais de maior risco para a ocorrência de

homicídios (de forma preditiva), e a respectiva roteirização para o melhor atendimento dos pontos com necessidade de atuação identificados.

Logo, a partir da avaliação comparativa entre o Risk Terrain Modeling, a p-medianas, o problema de localização de máxima cobertura e k-means, a fim de definir qual apresentava melhores resultados no aspecto preditivo. Assim, o RTM apresentou melhores resultados tanto para o modelo de cobertura de 5% da área da unidade operacional, quanto para o modelo que considerou o atendimento de 10% da extensão avaliada, atingindo o índice de assertividade de 31% e 43%, respectivamente.

Nota-se que os índices de acerto são relevantes, comparando-se com outros trabalhos sobre o método do RTM e demais métodos estudados, mesmo diante de crime com menor incidência, como é o caso dos crimes de homicídios.

A partir da identificação e verificação da relação dos fatores de risco selecionados para o crime de homicídios na área do Batalhão (zonas de atuação de gangues e tráfico de drogas, locais de violência interpessoal e de conflitos violentos cotidianos, pontos de incidência de homicídios, lugares de ocorrências de arma de fogo e áreas de vulnerabilidade), verificou-se a possibilidade de utilização do método no modelo proposto, para a localização de viaturas nos locais com maior risco, não considerando a incidência anterior do crime analisado, mas de informações que indicam que determinado local é apresenta-se com maior possibilidade de eventos de homicídio.

Ainda, quanto a isso, cabe salientar que a aplicabilidade do modelo foi ainda mais relevante por sua aplicação considerando períodos menores de análise para a indicação dos pontos de formas mensal, a partir dos dados do trimestre anterior. Assim, diferente da maioria dos estudos anteriores do RTM, que utilizavam dados de semestre ou ano, para indicação dos pontos de maior risco para período de com mesma amplitude, o modelo, no que tange a localização, permite um planejamento variável, para cada período mensal, partindo dos dados dos fatores para cada período de análise. Nesse sentido não houve repetição completa de planejamento (solução) com os pontos exatamente coincidentes, considerando esses subsequentes.

Destaca-se que o planejamento operacional de patrulhas policiais não se encerra na identificação dos “melhores” pontos para localização dos recursos, com vistas a prevenção, mas diante dos recursos limitados, indicar a melhor forma de atendimento desses pontos, se possível com a possibilidade de reduzir a necessidade de recursos.

Assim, a segunda fase do modelo propõe o estabelecimento de rotas que sejam mais adequadas, para o atendimento das demandas. Partindo de uma solução com base em uma heurística construtiva gulosa simples, que se aproxima da forma natural de pensar na definição de uma rota definida com base na experiência e conhecimento da área, comparou-se com uma roteirização estabelecida com a metaheurística Busca Tabu na solução de um problema clássico de roteirização de veículos com janela de tempo.

Nesta análise observou-se que as rotas estabelecidas com a Busca Tabu, considerando 34 pontos de cobertura, apresentaram em média 18% de redução no tempo e 20% de redução de distância percorrida. Considerando o cumprimento diário de cada rota, a redução de distância percorrida em um mês seria de mais de 660km.

Da mesma forma, diante do cenário de roteirização para 17 pontos, a diminuição seria de cerca de 26% no tempo utilizado e 27% na distância percorrida. Sendo que nesse cenário, reduzindo o tempo dos turnos de serviço, haveria a possibilidade de realizar de forma eficiente as rotas, por mais de uma vez, permitindo uma maior atuação nos locais de risco de homicídios, com a expectativa de que uma quantidade considerável pudesse ser evitada, a partir da presença policial de maneira ostensiva.

Por outro lado, os testes realizados com algoritmo para a solução exata, considerando tratar-se de um problema np-hard, com rápido crescimento fatorial na quantidade de soluções possíveis, a melhor solução após 24 horas de execução foi apenas 0,63% melhor do que as soluções geradas através do Busca Tabu, diante das mesmas instâncias. Mas, com o algoritmo do Busca Tabu, o tempo de execução foi mais de dez mil vezes menor do que a solução proposta através do Pulp/CPLEX, com a formulação para solução exata.

Integrando as duas fases, a pesquisa propõe um Modelo Preditivo de Localização e Roteirização de Patrulhas, testado com dados reais, mostrando-se uma proposta de policiamento inteligente com a possibilidade de aplicação, permitindo um aperfeiçoamento das medidas de gestão. A proposta completa o ciclo de policiamento inteligente preditivo, considerando a coleta de dados, análise preditiva na produção de um planejamento de operações policiais, com a expectativa, a partir de sua execução, de alteração na resposta criminal, com a redução dos eventos criminais. Diante de uma proposta de atuação proativa nos locais de maior risco, com a possibilidade de ser cumprida, mesmo diante de recursos limitados.

A partir da pesquisa, vislumbra-se o encaminhamento de novas possibilidades de incremento de modelos preditivos integrados, de forma a permitir um planejamento completo das ações policiais para a melhoria da segurança pública.

REFERÊNCIAS

- ANDRADE, Eduardo Leopoldino de. Introdução à pesquisa operacional: métodos e modelos para análise de decisões. 4 ed. - Rio de Janeiro: LTC, 2009.
- AZEVEDO, Rodrigo Ghiringhelli; CIPRIANI, Marcelli. Um estudo comparativo entre facções: o cenário de Porto Alegre e o de São Paulo. *Sistema penal & violência*, v. 7, n. 2, p. 161-174, 2015. BALLESTEROS, Paula Rodrigues. Gestão de políticas de segurança pública no Brasil: problemas, impasses e desafios. **Revista Brasileira de Segurança Pública**. v. 8, n. 1, 2014, p. 6 – 22. <https://doi.org/10.15448/2177-6784.2015.2.22162>
- BALLESTEROS, Paula Rodriguez. Gestão de políticas de segurança pública no Brasil: problemas, impasses e desafios. **Revista Brasileira de Segurança Pública**, v. 8, n. 1, 2014. Disponível em: <https://www.revista.forumseguranca.org.br/index.php/rbsp/article/view/353>
- BARNUM, Jeremy D. et al. The crime kaleidoscope: A cross-jurisdictional analysis of place features and crime in three urban environments. **Applied Geography**, v. 79, p. 203-211, 2017. <https://doi.org/10.1016/j.apgeog.2016.12.011>
- BASILIO, Marcio Pereira; PEREIRA, Valdecy; COSTA, Helder Gomes. Método De Apoio Decisão Multicritério: Um Estudo Empírico Aplicado na Classificação das Áreas Integradas de Segurança Pública no Estado do Rio de Janeiro. **Engevista**, v. 21, n. 1, p. 47-62, 2019. Disponível em: <https://periodicos.uff.br/engevista/article/view/10129>
- BAYLEY, David H. Padrões de Policiamento: Uma Análise Internacional Comparativa. São Paulo: Editora da Universidade de São Paulo, 2002.
- BEATO FILHO, Cláudio Chaves. Ação e estratégia das organizações policiais. **Revista Unidade**, Porto Alegre, nº 66, p.79-100, 2009.
- BOWERS, Kate J.; JOHNSON, Shane D.; GUERETTE, Rob T.; SUMMERS, Lucia; POYNTON, Suzanne. Spatial displacement and diffusion of benefits among geographically focused policing initiatives: A meta-analytical review. **Journal of Experimental Criminology**, 7(4), 347–374, 2011. <https://doi.org/10.1007/s11292-011-9134-8>
- BRAGA, Anthony A. Hot spots policing and crime prevention: A systematic review of randomized controlled trials. **Journal of Experimental Criminology**, 1, 317–342, 2005.
- BRAGA, Anthony A.; TURCHAN, Brandon; PAPACHRISTOS, Andrew V.; HUREAU, David M. Hot spots policing of small geographic areas effects on crime. **Campbell Systematic Reviews**, 15(3), 2019. <https://doi.org/10.1002/c12.1046>.
- BULLA, Patricia; RAMIREZ, Boris; GARCIA, Juan Felipe; LOVERA, María Paula; WIESNER, Daniel (2016). Homicidios y venta de drogas: una peligrosa dupla en Bogotá. Bogotá: Fundación Ideas para la Paz.
- CALDERÍN, Jenny Fajardo; MASEGOSA, Antonio D.; PELTA, David A. An algorithm portfolio for the dynamic maximal covering location problem. **Memetic Computing**, v. 9, n. 2, p. 141-151, 2017. <https://doi.org/10.1007/s12293-016-0210-5>
- CAMPELLO, Ruy E. **Algoritmos e heurísticas: desenvolvimento e avaliação de performance**. EDUFF, 1994.
- CAPAR, Ibrahim; KESKIN, Burcu B.; RUBIN, Paul A. An improved formulation for the maximum coverage patrol routing problem. **Computers & Operations Research**, v. 59, p. 1-10, 2015. <https://doi.org/10.1016/j.cor.2014.12.002>

- CAPLAN, Joel M.; KENNEDY, Leslie W.; MILLER, Joel. Risk terrain modeling: Brokering criminological theory and GIS methods for crime forecasting. **Justice quarterly**, v. 28, n. 2, p. 360-381, 2011. <https://doi.org/10.1080/07418825.2010.486037>
- CAPLAN, Joel M.; KENNEDY, Leslie W. Risk terrain modeling compendium. **Rutgers Center on Public Security, Newark**, p. 51, 2011. Disponível em: http://www.rutgerscps.org/uploads/2/7/3/7/27370595/riskterrainmodelingcompendium_caplan_kennedy2011.pdf
- CAPLAN, Joel M.; KENNEDY, Leslie W. Risk terrain modeling diagnostics utility (Version 1.0). **Newark, NJ: Rutgers Center on Public Security**, 2013.
- CAPLAN, Joel M.; KENNEDY, Leslie W.; PIZA, Eric L. Joint utility of event-dependent and environmental crime analysis techniques for violent crime forecasting. **Crime & Delinquency**, v. 59, n. 2, p. 243-270, 2013. <https://doi.org/10.1177/0011128712461901>
- CAPLAN, Joel M. Caplan, J, KENNEDY, Leslie W; BARNUM, Jeremy D; PIZA, Eric. Risk terrain modeling for spatial risk assessment. **Cityscape**, v. 17, n. 1, p. 7-16, 2015. <http://www.jstor.org/stable/26326918>
- CAPLAN, Joel M. et al. Crime in context: Utilizing risk terrain modeling and conjunctive analysis of case configurations to explore the dynamics of criminogenic behavior settings. **Journal of contemporary criminal justice**, v. 33, n. 2, p. 133-151, 2017. <https://doi.org/10.1177/1043986216688814>
- CARVALHO, Maria do Socorro Macedo Vieira de, e TONET, Helena Corrêa. Qualidade na administração pública. **Revista de Administração Pública**, Rio de Janeiro : FGV, v.28, n. 2, p.137-152, abr./jun. 1994.
- CERQUEIRA, Daniel Ricardo de Castro; LOBÃO, Waldir; CARVALHO, Alexandre. O jogo dos sete mitos e a miséria da segurança pública no Brasil. Brasília: IPEA, dez, 2005, 30 p.
- CERQUEIRA, D. et al. Atlas da violência 2020. Brasília: IPEA. 2020. <https://dx.doi.org/10.38116.riatlasdaviolencia2020>
- CHANEY, Spencer; TOMPSON, Lisa; & UHLIG, Sebastian. The utility of hotspot mapping for predicting spatial patterns of crime. **Security Journal**, 21(1-2), 4-28, 2008. <https://link.springer.com/article/10.1057/palgrave.sj.8350066>
- CHOW, Andy HF; CHEUNG, C. Y.; YOON, H. T. Optimization of police facility locationing. **Transportation research record**, v. 2528, n. 1, p. 60-68, 2015. <https://doi.org/10.3141/2528-07>
- CHURCH, Richard; REVELLE, Charles. The maximal covering location problem. In: **Papers of the regional science association**. Springer-Verlag, 1974. p. 101-118. http://yalma.fime.uanl.mx/~roger/work/teaching/class_tso/docs_project/problems/MCLP/1974-prs-Church%20ReVelle-maximal%20covering%20location.pdf
- CIPRIANI, Marcelli. Da “Falange Gaúcha” aos “Bala nos Bala”: a emergência das “facções criminais” em Porto Alegre (RS) e sua manifestação atual. **Direito e Democracia – Revista de Ciências Jurídicas**. Canoas, 17 (1), 2016, p. 105-130.
- COLDREN JR, James R.; HUNTOON, Alissa; MEDARIS, Michael. Introducing smart policing: Foundations, principles, and practice. **Police quarterly**, v. 16, n. 3, p. 275-286, 2013. <https://doi.org/10.1177/1098611113497042>

- CORDEAU, Jean-François; LAPORTE, Gilbert; MERCIER, Anne. A unified tabu search heuristic for vehicle routing problems with time windows. **Journal of the Operational research society**, v. 52, n. 8, p. 928-936, 2001. <https://doi.org/10.1057/palgrave.jors.2601163>
- CORDNER, Gary W.; GREENE, Jack R.; BYNUM, Tim S. Planejamento dos Recursos Humanos Policiais. JR Greene, **Administração do Trabalho Policial: Questões e Análises**, p. 61-83, 2007.
- DALEY, Dyann ; BACHMANN, Michael; BACHMANN, Brittany A.; PEDIGO, Christian; BUI, Minh-Thuy; COFFMAN, Jamye. Risk terrain modeling predicts child maltreatment. **Child Abuse & Neglect**, Volume 62, 2016, Pages 29-38, 2016. <https://doi.org/10.1016/j.chiabu.2016.09.014>.
- DANTZIG, George B.; RAMSER, John H. The truck dispatching problem. **Management science**, v. 6, n. 1, p. 80-91, 1959. <https://doi.org/10.1287/mnsc.6.1.80>
- DASH, Saroj Kumar; SAFRO, Ilya; SRINIVASAMURTHY, Ravisutha Sakrepatna. Spatio-temporal prediction of crimes using network analytic approach. In: **2018 IEEE International Conference on Big Data (Big Data)**. IEEE, 2018. p. 1912-1917. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8622041>
- DEWIL, Reginald et al. A minimum cost network flow model for the maximum covering and patrol routing problem. **European Journal of Operational Research**, v. 247, n. 1, p. 27-36, 2015. <https://doi.org/10.1016/j.ejor.2015.05.067>
- DEWINTER, Maite; VANDEVIVER, Christophe; BEKEN, Tom Vander; WITLOX, Frank. Analysing the police patrol routing problem: A review. **ISPRS International Journal of Geo-Information**, v. 9, n. 3, p. 157, 2020. <https://doi.org/10.3390/ijgi9030157>
- DUGATO, Marco; CALDERONI, Francesco; BERLUSCONI, Giulia. Forecasting organized crime homicides: Risk terrain modeling of camorra violence in Naples, Italy. **Journal of interpersonal violence**, v. 35, n. 19-20, p. 4013-4039, 2020. <https://doi.org/10.1177/0886260517712275>
- ENGEL, Cíntia Liara; et al. Diagnóstico dos homicídios no Brasil: subsídios para o Pacto Nacional pela Redução de Homicídios. Brasília: Ministério da Justiça, Secretaria Nacional de Segurança Pública, 2015, 272p.
- FOLIUM. python-visualization. *Folium*. Disponível em: <https://python-visualization.github.io/folium/>
- FREITAS, Juarez. Direito fundamental à boa administração pública e o reexame dos institutos da autorização de serviço público, da convalidação e do “poder de polícia administrativa”. In: ARAGÃO, Alexandre Santos de; MARQUES NETO, Floriano de Azevedo (coord.). *Direito Administrativo e seus novos paradigmas* – Belo Horizonte: Fórum, 2008, p. 311-334.
- FROTA, Marcos Tadeu Ellery. Determinantes dos homicídios no Brasil. Fortaleza, CE. Dissertação de mestrado. Universidade Federal do Ceará, 2014, 88 p.
- GELINSKI NETO, Francisco; SILVA, Jediael Emanuel Pereira da. A Prevenção e o Controle da Violência e Criminalidade: programas exitosos. Joinville: APEC/UNIVILE, 2012.
- GENDREAU, Michel; HERTZ, Alain; LAPORTE, Gilbert. A tabu search heuristic for the vehicle routing problem. **Management science**, v. 40, n. 10, p. 1276-1290, 1994. <https://doi.org/10.1287/mnsc.40.10.1276>

GIMÉNEZ-SANTANA, Alejandro; CAPLAN, Joel M.; DRAWVE, Grant. Risk Terrain Modeling and Socio-Economic Stratification: Identifying Risky Places for Violent Crime Victimization in Bogotá, Colombia. **Eur J Crim Policy Res** **24**, 417–431 (2018).

GLOVER, Fred. Future paths for integer programming and links to artificial intelligence. **Computers & operations research**, v. 13, n. 5, p. 533-549, 1986. [https://doi.org/10.1016/0305-0548\(86\)90048-1](https://doi.org/10.1016/0305-0548(86)90048-1)

GLOVER, Fred. Tabu search: A tutorial. **Interfaces**, v. 20, n. 4, p. 74-94, 1990. <https://doi.org/10.1287/inte.20.4.74>

GOOGLE OR-TOOLS. OR-Tools 7.2. Laurent Perron and Vincent Furnon. Google. <https://developers.google.com/optimization/>

GOLDBARG, Elizabeth; GOLDBARG, Marco; LUNA, Henrique. **Otimização combinatória e metaheurísticas: algoritmos e aplicações**. Elsevier Brasil, 2016.

GRUPO DE PESQUISA EM ANALYTICS - UFRGS. **Analytics para ajudar a melhorar a segurança pública**. Porto Alegre. 05 nov. 2021. Instagram: @gpaeaufrgs. Disponível em <https://www.instagram.com/p/CV5rvQ7JPPQ/>. Acesso em: 20 dez. 2021

GRABOSKY, Peter N. Fear of crime, and fear reduction strategies. Current issues in criminal justice, v. 7, n. 1, p. 7-19, 1995. Disponível em: <https://www.aic.gov.au/sites/default/files/2020-05/tandi044.pdf>

GURGEL, A. M.; FERREIRA, R. J. P.; ALOISE, D. J. Modelagem de problemas da segurança pública: Uma proposta de modelos para a localização de bases policiais e roteirização de viaturas. Anais XXX Encontro Nacional de Engenharia de Produção, ENEGEP 2010, 2010. Disponível em: http://www.abepro.org.br/biblioteca/TN_STO_263_509_36296.pdf

GUSMÃO, Ana Paula Henriques de; COSTA BORBA, Bruno Ferreira da; CLEMENTE, Thárcylla Rebecca Negreiros. Management information system for police facility location. In: **International conference on decision support system technology**. Springer, Cham, 2020. p. 86-98. https://doi.org/10.1007/978-3-030-46224-6_7

GUSSI, Evandro Herrera, Betone. A segurança na Constituição. Dissertação apresentada no Programa de Pós-Graduação em Direito da Universidade Federal do Rio Grande do Sul como requisito parcial para a obtenção do grau de mestre. Porto Alegre, 2005.

HAKIMI, S. Louis. Optimum locations of switching centers and the absolute centers and medians of a graph. **Operations research**, v. 12, n. 3, p. 450-459, 1964. <https://doi.org/10.1287/opre.12.3.450>

HART, Timothy; ZANDBERGEN, Paul. Kernel density estimation and hotspot mapping: Examining the influence of interpolation method, grid cell size, and bandwidth on crime forecasting. **Policing: An International Journal of Police Strategies & Management**, 2014. <https://doi.org/10.1108/PIJPSM-04-2013-0039>

HILLIER, Frederick S.; LIEBERMAN, Gerald J. **Introdução à pesquisa operacional**. – São Paulo : McGraw-Hill, 2006.

HUTT, Oliver et al. Data and evidence challenges facing place-based policing. **Policing: An International Journal**, 2018. <https://doi.org/10.1108/PIJPSM-09-2017-0117>

INGILEVICH, Varvara; IVANOV, Sergey. Crime rate prediction in the urban environment using social factors. **Procedia Computer Science**, v. 136, p. 472-478, 2018. <https://doi.org/10.1016/j.procs.2018.08.261>

- JAIN, Anil K. Data clustering: 50 years beyond K-means. **Pattern recognition letters**, v. 31, n. 8, p. 651-666, 2010. <https://doi.org/10.1016/j.patrec.2009.09.011>
- JENSEN, Paul A.; BARD, Jonathan F. Operations research models and methods. John Wiley & Sons, 2003.
- JOHNSON, Shane D. A brief history of the analysis of crime concentration. **European Journal of Applied Mathematics**, 21(4-5), 349-370, 2010. <http://doi.org/10.1017/S0956792510000082>
- KARATAS, Mumtaz; RAZI, Nasuh; TOZAN, Hakan. A Comparison of p-median and Maximal Coverage Location Models with Q-coverage Requirement. **Procedia Engineering**, v. 149, p. 169-176, 2016. <https://doi.org/10.1016/j.proeng.2016.06.652>
- KENNEDY, Leslie W.; CAPLAN, Joel M.; PIZA, Eric. Risk clusters, hotspots, and spatial intelligence: risk terrain modeling as an algorithm for police resource allocation strategies. **Journal of quantitative criminology**, v. 27, n. 3, p. 339-362, 2011. <https://doi.org/10.1007/s10940-010-9126-2>
- KENNEDY, Leslie W.; CAPLAN, Joel M.; PIZA, Eric. *et al.* Vulnerability and exposure to crime: Applying risk terrain modeling to the study of assault in Chicago. **Applied Spatial Analysis and Policy**, v. 9, n. 4, p. 529-548, 2016. <https://doi.org/10.1007/s12061-015-9165-z>
- KENNEDY, Leslie W.; DUGATO, Marco. Forecasting crime and understanding its causes. Applying risk terrain modeling worldwide. **European Journal on Criminal Policy and Research**, v. 24, n. 4, p. 345-350, 2018. Disponível em: <https://link.springer.com/article/10.1007/s10610-018-9404-3>
- KESKIN, Burcu B; LI, Shirley; STEIL, Dana; SPILLER, Sarah. Analysis of an integrated maximum covering and patrol routing problem. **Transportation Research Part E: Logistics and Transportation Review**, v. 48, n. 1, p. 215-232, 2012. <https://doi.org/10.1016/j.tre.2011.07.005>
- KLOSE, Andreas; DREXL, Andreas. Facility location models for distribution system design. **European journal of operational research**, v. 162, n. 1, p. 4-29, 2005. <https://doi.org/10.1016/j.ejor.2003.10.031>
- KOPER, Christopher 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, 1995. <https://doi.org/10.1080/07418829500096231>
- LAPORTE, Gilbert. The vehicle routing problem: An overview of exact and approximate algorithms. **European journal of operational research**, v. 59, n. 3, p. 345-358, 1992. [https://doi.org/10.1016/0377-2217\(92\)90192-C](https://doi.org/10.1016/0377-2217(92)90192-C)
- LAPORTE, Gilbert. What you should know about the vehicle routing problem. **Naval Research Logistics (NRL)**, v. 54, n. 8, p. 811-819, 2007. <https://doi.org/10.1002/nav.20261>
- LENSTRA, Jan Karel; KAN, AHG Rinnooy. Complexity of vehicle routing and scheduling problems. **Networks**, v. 11, n. 2, p. 221-227, 1981. <https://doi.org/10.1002/net.3230110211>
- LIMEIRA, Marcio Luiz da Costa ; DONATO, Roberto dos Santos; SIMOES JÚNIOR, Moacir Almeida. Reduction of homicides in Porto Alegre: fighting criminal factions. **Public Security and Public Order**, n. 28, 2021. <https://doi.org/10.13165/PSPO-21-28-06>
- LIN, Ying-Lung; YEN, Meng-Feng; YU, Liang-Chih. Grid-based crime prediction using geographical features. **ISPRS International Journal of Geo-Information**, v. 7, n. 8, p. 298, 2018. <https://doi.org/10.3390/ijgi7080298>

- MACIEL, Marcos Vinicius Milan; LIMEIRA, Marcio Luiz da Costa; FERREIRA, Luciano . Uma abordagem heurística para o planejamento de rotas para patrulhas Maria da Penha. In: Anais do LIII Simpósio Brasileiro de Pesquisa Operacional, 2021, João Pessoa. **Anais eletrônicos...** Campinas, Galoá, 2021. Disponível em: <https://proceedings.science/sbpo-series/sbpo-2021/papers/uma-abordagem-heuristica-para-o-planejamento--de-rotas-para-patrulhas-maria-da-penha> Acesso em: 14 jan. 2022.
- MARCHMENT, Zoe; GILL, Paul. Systematic review and meta-analysis of risk terrain modelling (RTM) as a spatial forecasting method. **Crime Science**, v. 10, n. 1, p. 1-11, 2021. <https://doi.org/10.1186/s40163-021-00149-6>
- MEIJER, Albert; WESSELS, Martijn. Predictive policing: Review of benefits and drawbacks. **International Journal of Public Administration**, v. 42, n. 12, p. 1031-1039, 2019. <http://10.1080/01900692.2019.1575664>
- MELLO, Celso Antônio Bandeira de. Curso de Direito Administrativo. 26. ed., revista e atualizada. São Paulo: Malheiros Editores, 2009
- MITCHELL, Stuart; OSULLIVAN, Michael; DUNNING, Iain. PuLP: a linear programming toolkit for python. **The University of Auckland, Auckland, New Zealand**, v. 65, 2011. Disponível em: <https://www.dit.uoi.gr/e-class/modules/document/file.php/216/PAPERS/2011.%20PuLP%20-%20A%20Linear%20Programming%20Toolkit%20for%20Python.pdf>
- MOHLER, George O. et al. Self-exciting point process modeling of crime. **Journal of the American Statistical Association**, v. 106, n. 493, p. 100-108, 2011. <https://doi.org/10.1198/jasa.2011.ap09546>
- MORETO, William D.; PIZA, Eric L.; CAPLAN, Joel M. “A plague on both your houses?”: Risks, repeats and reconsiderations of urban residential burglary. **Justice Quarterly**, v. 31, n. 6, p. 1102-1126, 2014. <https://doi.org/10.1080/07418825.2012.754921>
- MOSES, Lyria Bennett; CHAN, Janet. Algorithmic prediction in policing: assumptions, evaluation, and accountability, **Policing and Society**, 28:7, 806-822, 2018. <https://doi.org/10.1080/10439463.2016.1253695>
- MURRAY, Alan T. Maximal coverage location problem: impacts, significance, and evolution. **International Regional Science Review**, v. 39, n. 1, p. 5-27, 2016. <https://doi.org/10.1177/0160017615600222>
- MURRAY, Joseph; DE CASTRO CERQUEIRA, Daniel Ricardo; KAHN, Tulio. Crime and violence in Brazil: Systematic review of time trends, prevalence rates and risk factors. **Aggression and violent behavior**, v. 18, n. 5, p. 471-483, 2013. <https://doi.org/10.1016/j.avb.2013.07.003>
- OBSERVAPOA. Observatório da Cidade de Porto Alegre. Disponível em: <http://www.observapoa.com.br/default.php>
- OLIVEIRA, M. G. **Sistema de localização de facilidades: uma abordagem para mensuração de pontos de demanda e localização de facilidades. 2012. 91f.** 2012. Tese de Doutorado. Dissertação (Mestrado em Ciências da Computação). Universidade Federal de Goiás, Goiás.
- OLIVEIRA, Washington Alves de; MORETTI, Antonio Carlos; REIS, Ednei Felix. Multi-vehicle covering tour problem: building routes for urban patrolling. **Pesquisa Operacional**, v. 35, n. 3, p. 617-644, 2015. <https://doi.org/10.1590/0101-7438.2015.035.03.0617>

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M., *et al.* Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2011, 2825–2830

PERRY, Walt L. Predictive policing: The role of crime forecasting in law enforcement operations. Rand Corporation, 2013. Disponível em: https://www.rand.org/content/dam/rand/pubs/research_reports/RR200/RR233/RAND_RR233.pdf

PIZA, Eric; FENG, Shun; KENNEDY, Leslie; CAPLAN, Joel (2017). Place-based correlates of motor vehicle theft and recovery: Measuring spatial influence across neighbourhood context. *Urban Studies*, v. 54, n. 13, p. 2998-3021, 2017. <https://doi.org/10.1177/0042098016664299>

QGIS Development Team. QGIS Geographic Information System. Open Source Geospatial Foundation Project. Disponível em: <http://qgis.osgeo.org>

RAGSDALE, Cliff T. Modelagem e análise de decisão. **São Paulo: Cengage Learning**, 2009.

RATCLIFFE, Jerry. Crime Mapping: Spatial and Temporal Challenges. In: Handbook of Quantitative Criminology. In **Handbook of Quantitative Criminology**, 2010. https://link.springer.com/chapter/10.1007/978-0-387-77650-7_2

RATCLIFFE, Jerry H.; TAYLOR, Ralph B.; FISHER, Ryan. Conflicts and congruencies between predictive policing and the patrol officer's craft. **Policing and Society**, 2019. <https://doi.org/10.1080/10439463.2019.1577844>

RODRIGUES, Fabiano; RUSSO, Rosária de Fátima Segger Macri. Heurísticas e vieses. In: **Tomada de Decisão nas Organizações: uma visão multidisciplinar**. Abraham Sin Oih Yu (Coord.) – São Paulo: Saraiva, 2011, p.79-108.

ROSSER, Gabriel; BOWERS, Kate; JOHNSON, Shane; CHENG, Tao. Predictive crime mapping: Arbitrary grids or street networks? **Journal of quantitative criminology**, v. 33, n. 3, p. 569-594, 2017. Disponível em: <https://link.springer.com/article/10.1007/s10940-016-9321-x>

RUMMENS, Anneleen; HARDYNS, Wim; PAUWELS, Lieven (2017). The use of predictive analysis in spatiotemporal crime forecasting: Building and testing a model in an urban context. **Applied Geography**, 86, 255–261. <https://doi.org/10.1016/j.apgeog.2017.06.011>

SAPORI, Luis Flavio ; SENA, Lucia Lamounier ; SILVA, Bráulio Figueiredo Alves da. Mercado do crack e violência urbana na cidade de Belo Horizonte. **DILEMAS: Revista de Estudos de Conflito e Controle Social**, Rio de Janeiro, 5(1), 2012, p. 37-66.

SECRETARIA DA SEGURANÇA PÚBLICA. Estatísticas. Secretaria da Segurança Pública do Estado do Rio Grande do Sul, 2021. Disponível em: <https://ssp.rs.gov.br/estatisticas> . Acesso em: 8 de novembro de 2021.

SHARMA, Satyendra Kumar; ROUTROY, Srikanta; YADAV, Utkarsh. Vehicle routing problem: recent literature review of its variants. **International Journal of Operational Research**, v. 33, n. 1, p. 1-31, 2018. <https://www.inderscienceonline.com/doi/abs/10.1504/IJOR.2018.094229>

SILVA, Valtania Ferreira da; CABRAL, Lucídio dos Anjos Formiga; QUIRINO, Roberto. Estratégia para seleção de locais candidatos voltada ao problema de localização de viaturas

- policiais. **XLVSBPO-Simpósio Brasileiro de Pesquisa Operacional, Natal, 2013.**
Disponível em: <http://www.din.uem.br/~ademir/sbpo/sbpo2013/pdf/arq0357.pdf>
- SIMPSON, N. C.; HANCOCK, Philip G. Fifty years of operational research and emergency response. **Journal of the Operational Research Society**, v. 60, n. sup1, p. S126-S139, 2009.
<https://doi.org/10.1016/j.ejor.2013.01.039>
- SINCLAIR, Christopher; DAS, Saptarshi. Traffic Accidents Analytics in UK Urban Areas using k-means Clustering for Geospatial Mapping. In: **2021 International Conference on Sustainable Energy and Future Electric Transportation (SEFET)**. IEEE, 2021. p. 1-7.
<https://doi.org/10.1109/SeFet48154.2021.9375817>
- STEINMAN, Hannah; DRAWVE, Grant; DATTA, Jyotishka; HARRIS, Casey T.; THOMAS, Shaun A. Risky business: Examining the 80-20 rule in relation to a RTM framework. **Criminal Justice Review**, v. 46, n. 1, p. 20-39, 2021.
<https://doi.org/10.1177/0734016820938859>.
- TAILLARD, Éric et al. A tabu search heuristic for the vehicle routing problem with soft time windows. **Transportation science**, v. 31, n. 2, p. 170-186, 1997.
<https://doi.org/10.1287/trsc.31.2.170>
- TALBI, El-Ghazali. **Metaheuristics: from design to implementation**. John Wiley & Sons, 2009.
- VALASIK, Matthew; BRAULT, Elizabeth E.; MARTINEZ, Stephen M. Forecasting homicide in the red stick: Risk terrain modeling and the spatial influence of urban blight on lethal violence in Baton Rouge, Louisiana. **Social Science Research**, v. 80, p. 186-201, 2019.
<https://doi.org/10.1016/j.ssresearch.2018.12.023>
- VANAGUNAS, Stanley. Planejamento dos Serviços Policiais. **Administração do Trabalho Policial-Questões e Análises** Vol. 5, v. 5, p. 43, 2007.
- WEISBURD, David. The law of crime concentration and the criminology of place." **Criminology** 53, no. 2 : 133-157, 2015. <https://doi.org/10.1111/1745-9125.12070>
- WHEELER, Andrew Palmer. Creating optimal patrol areas using the p-median model. **Policing: An International Journal**, 2018. <https://doi.org/10.1108/PIJPSM-02-2018-0027>
- WOLSEY, Laurence A. **Integer programming**. John Wiley & Sons, 1998.
- YADAV, Sunil; TIMBADIA, Meet; YADAV, Ajit; VISHWAKARMA, Rohit; YADAV, Nikhilesh. "Crime pattern detection, analysis & prediction." In **2017 International conference of Electronics, Communication and Aerospace Technology (ICECA)**, vol. 1, pp. 225-230. IEEE, 2017.
- YASSEN, Esam Taha; ARRAM, Anas; AYOB, Masri; ZAKREE, Mohd; NAZRI, Ahmad I. A constructive heuristic for police patrol routing problems. **Pertanika J. Sci. Technol**, v. 25, p. 87-96, 2017.
[http://www.pertanika.upm.edu.my/resources/files/Pertanika%20PAPERS/JST%20Vol.%2025%20\(S\)%20Jun.%202017/09%20JST\(S\)-0378-2017-6thProof.pdf](http://www.pertanika.upm.edu.my/resources/files/Pertanika%20PAPERS/JST%20Vol.%2025%20(S)%20Jun.%202017/09%20JST(S)-0378-2017-6thProof.pdf)
- ZHU, Qing et al. An anticrime information support system design: Application of K-means-VMD-BiGRU in the city of Chicago. **Information & Management**, p. 103247, 2019.
<https://doi.org/10.1016/j.im.2019.103247>