

Análise de otimização de pontos para abertura de novas unidades policiais

Gustavo R. Carvalho¹, Nádia P. Kozievitch¹, Leonardo S. Zavadzki¹

¹PPGCA – Universidade Tecnológica Federal do Paraná (UTFPR)
Avenida Sete de Setembro – 3165 – 80.230-901 – Curitiba – PR – Brasil

gu171994@gmail.com, nadiap@utfpr.edu.br, leonardoz@alunos.utfpr.edu.br

Abstract. *Public safety issues in large urban centers cause significant harm to society. To mitigate this, the strategic distribution of police units is essential. This ongoing work presents an analysis of geospatial data from the Greater London area, verifying the effectiveness of the distribution of police units and their adequacy to public safety needs, considering crime patterns.*

Resumo. *Problemas de segurança pública em grandes centros urbanos causam prejuízos significativos à sociedade. Para mitigar isso, a distribuição estratégica de unidades policiais é fundamental. Este trabalho em andamento apresenta uma análise de dados geoespaciais da região metropolitana de Londres, verificando a eficácia da distribuição de unidades policiais e sua adequação às necessidades de segurança pública, considerando padrões de criminalidade.*

1. Introdução

A otimização da distribuição de unidades policiais é um desafio enfrentado por diversas cidades ao redor do mundo. A alocação estratégica de recursos pode melhorar significativamente a eficácia das operações policiais, como demonstrado em estudos que utilizam dados geoespaciais e técnicas de clusterização para identificar áreas de alta incidência criminal. A pesquisa de [Sathiyanarayanan et al. 2019] destaca que a análise espacial para identificar hotspots, evidencia áreas com alta concentração de crimes, o que nos permite otimizar a cobertura e reduzir os tempos de resposta policial, maximizando a prevenção e o combate à criminalidade.

No contexto global, cidades como Londres enfrentam desafios semelhantes, com a necessidade de distribuir unidades policiais de forma eficiente para lidar com áreas de alta demanda. A literatura nacional também aponta que no Brasil a alocação desigual de recursos policiais contribui para a sobrecarga de algumas regiões e a falta de cobertura em outras. Estudos como o de [Araujo et al. 2017] destacam a importância da análise geoespacial para melhorar a cobertura policial em grandes centros urbanos, garantindo uma distribuição mais equitativa dos recursos.

Do ponto de vista computacional, técnicas como a clusterização K-Means, que organiza dados em K grupos, onde cada ponto é associado ao centro mais próximo, e os centros são ajustados iterativamente até que a formação dos grupos se estabilize, são amplamente utilizadas para processar grandes volumes de dados espaciais e identificar padrões de crimes. Essas metodologias, conforme evidenciado por estudos de [Wang et al. 2020],

permitem uma análise precisa e eficiente, recomendando locais ideais para novas unidades policiais. Considerando a limitação de gastos e a otimização de recursos em cidades, este trabalho em andamento utiliza dados abertos de Londres, visando identificar as três melhores localizações para novas delegacias.

2. Trabalhos correlatos

[Lilhare et al. 2024] mostra a importância de GIS e análise espacial na identificação e interpretação de hotspots de crimes. [Sheikh et al. 2017] detalha como essas ferramentas ajudam a mapear a distribuição dos crimes, enquanto [Kim et al. 2020] sugere que a visualização de dados, como mapas de densidade e pontos é crucial para a formulação de políticas e estratégias de segurança pública. Essas visualizações ajudam a identificar padrões e alocar recursos de forma mais eficaz, conforme detalhado por [Abhay et al. 2023].

No entanto, nenhum desses estudos abordou especificamente a distribuição de unidades policiais na região metropolitana de Londres, considerando análise espacial, padrões criminais e otimização de recursos. Essa lacuna justifica a presente pesquisa, que visa contribuir para uma distribuição mais eficiente dos recursos policiais, melhorando a segurança pública e auxiliando na redução da criminalidade na região.

3. Desenvolvimento

A base de dados utilizada para a pesquisa refere-se a dados de crimes individuais e incidentes de comportamentos antissociais (*ASB Anti-social Behaviour*) da região metropolitana de Londres, atendida pela *Metropolitan Police Service*(MPS)¹, incluindo informações de localização em nível de rua e os resultados subsequentes de ações policiais e judiciais associados ao crime. No período de Agosto-2023 a Agosto-2024, as unidades policiais foram importadas das *amenities*² para o banco de dados utilizando o QGis 3.22.4 64 bits³, selecionando a área tratada no estudo. Para analisar e tratar os dados, foram utilizados o PostgreSQL 17.2⁴, e o PostGIS 3.5⁵.

O processo de inserção de dados enfrentou desafios que comprometeram sua eficiência, sendo estes:

- Geração de identificadores únicos via planilha, utilizando um gerador sequencial a partir do número um, que tornou o carregamento lento devido ao alto volume de registros.
- A inserção parcial dos registros foi necessária por conta do limite de banda da rede e pela grande quantidade de dados.

Um total de 554.832 registros foram inseridos, indexados, geocodificados e atualizados para a projeção cartográfica EPSG:3395 (WGS 84/Pseudo Mercator) na base de dados. Considerando a limitação de gastos e a otimização de recursos em cidades, o

¹<https://data.police.uk/data/fetch/0a319eae-59b1-47d6-adcf-b485883123b3>

²<https://overpass-api.de/>

³<https://www.qgis.org/project/visual-changelogs/visualchangelog322>

⁴<https://www.postgresql.org/docs/17/index.html>

⁵<https://postgis.net/2024/09/PostGIS-3.5.0>

objetivo era responder à seguinte pergunta: **Quais são as três localizações mais adequadas para a instalação de uma nova unidade policial, considerando a distribuição e a quantidade de crimes na região?**

A abordagem utilizada possui as seguintes limitações: 1) o raio de abrangência das delegacias foi limitado a 2 km, considerando a rapidez e eficiência da abordagem de policiais; e 2) no processo de clusterização, foi utilizado K=4 (após vários testes), devido aos agrupamentos moderadamente definidos.

Em uma primeira etapa foram selecionadas as ocorrências de crimes em uma raio limite de 2 km das delegacias existentes (feita com a função ST_DWithin). O parâmetro foi escolhido devido à facilidade e tempo de resposta da operação dos policiais.

Em seguida, foi utilizado o algoritmo K-means, através da função ST_ClusterKmeans do PostGIS. A escolha se deu por sua eficiência e simplicidade na identificação de clusters com forma aproximadamente esférica. Valores entre 2 e 10 foram testados com o algoritmo K-Means, resultando em Elbow=3, Silhouette=2, Calinski-Harabasz=7. A definição do número de clusters foi realizada com base em experimentação orientada por métricas de avaliação. A escolha final considerou K=4, com Silhouette Score de 0.4570, Calinski-Harabasz de 332760.86 e Inertia de 3.73×10^3 , indicando uma maior separação entre os clusters.

A segunda etapa teve como objetivo identificar as melhores localizações para as novas unidades policiais, com a função ST_Centroid. Na Figura 1 é apresentado o resultado: 1) a cor roxa representa o agrupamento das ocorrências de crimes individuais e incidentes de comportamentos antissociais; 2) a distribuição das unidades de delegacias já existentes estão representadas pelas estrelas azuis; e 3) as localizações sugeridas para as novas unidades estão representadas pelos símbolos verdes. O objetivo foi otimizar o atendimento às áreas com maior concentração de ocorrências, e distantes das delegacias já existentes.

Para aprimorar ainda mais a eficácia dessas medidas, recomenda-se aos órgãos responsáveis, o aperfeiçoamento dos dados utilizando uma classificação mais detalhada dos delitos, considerando padrões temporais, índices de reincidência e especificidades das ocorrências, o que contribuiria para a identificação de áreas com maior necessidade de reforço policial. A integração da base de dados criminais com informações socioeconômicas e urbanísticas, tais como densidade populacional, iluminação pública, fluxo de pedestres e acessibilidade viária, possibilitaria uma alocação mais eficiente dos recursos, alinhada com as dinâmicas urbanas e sociais das regiões analisadas.

4. Conclusões

Este estudo em andamento utilizou dados abertos, e apresentou uma análise espacial da distribuição de crimes na região metropolitana de Londres, com o objetivo de identificar três localizações ideais para novas unidades policiais. O algoritmo K-Means revelou concentrações significativas de crimes, permitindo uma distribuição estratégica de recursos.

Entre os trabalhos futuros, destaca-se a necessidade de dados mais detalhados, análise temporal, inclusão de dados históricos e outros atributos relevantes além da localização geográfica, bem como a análise comparativa de diferentes algoritmos de

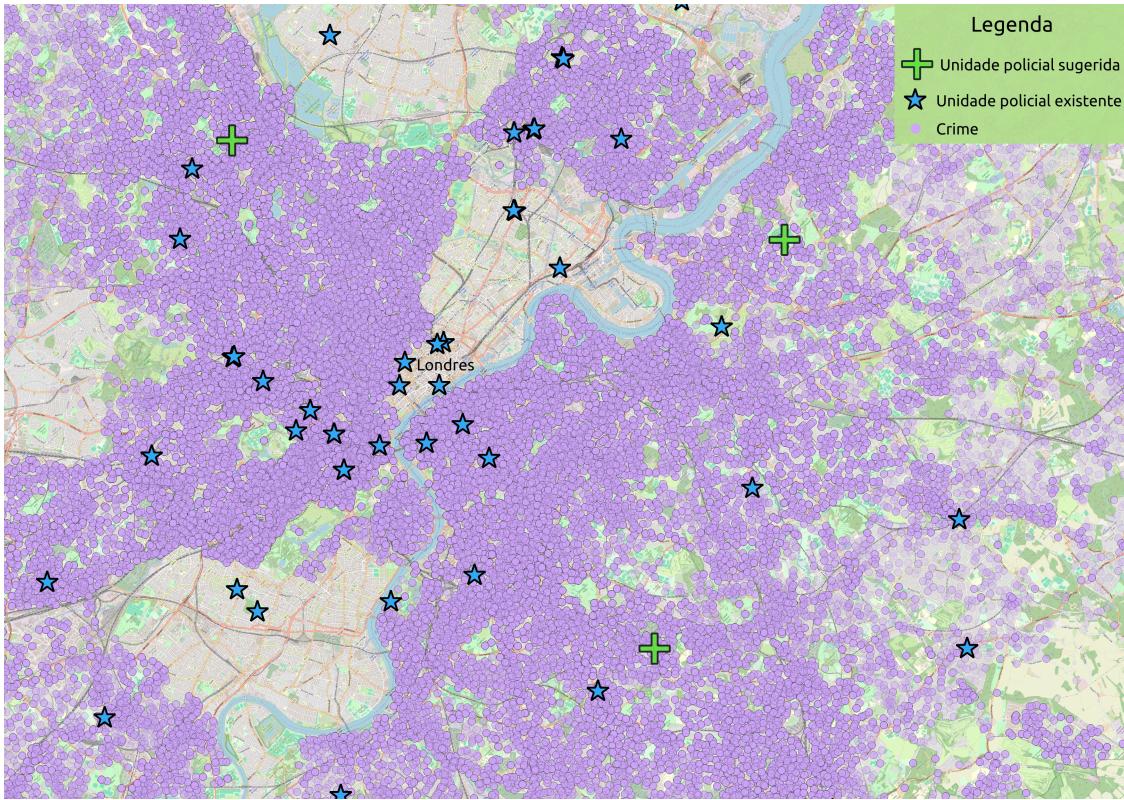


Figura 1. Locais para instalação das novas unidades policiais.

clusterização. Ademais, ressalta-se a importância da colaboração com especialistas do domínio para permitir uma avaliação qualitativa mais aprofundada dos resultados.

Referências

- Abhay, D. A., Akash, S., Ashwin, K., Shenoy, A. G., and Auradkar, P. K. (2023). Smart policing: Using geospatial crime data to plan patrol routes. In *2023 4th International Conference for Emerging Technology (INCET)*, pages 1–7.
- Araujo, A., Cacho, N., Thome, A. C., Medeiros, A., and Borges, J. (2017). A predictive policing application to support patrol planning in smart cities. *ISC2 2017*, pages 1–6.
- Kim, Y., Kim, G., Lee, Y., and Jang, K. (2020). Bandwidth selection of kernel density estimation for gis-based crime occurrence map visualization. *ICTC 2020*, pages 1705–1708.
- Lilhare, S. G., Kumavat, Y., Banait, G., and Kurkelli, A. (2024). Crime hotspots mapping and fir data interface. *ICICET 2024*, pages 1–7.
- Sathiyaranarayanan, M., Junejo, A. K., and Fadahunsi, O. (2019). Visual analysis of predictive policing to improve crime investigation. *IC3I 2019*, pages 197–203.
- Sheikh, J., Shafique, I., Sharif, M., Zahra, S. A., and Farid, T. (2017). Role of gis in crime mapping and analysis. *ComTech 2017*, pages 126–131.
- Wang, J., Zhang, S., Lan, Y., Wu, C., Xia, Y., and Chen, L. (2020). Crime analysis of spatial-temporal distribution based on knn algorithm. *ICISE-IE 2020*, pages 150–154.