

Avaliação Comparativa de Métodos de Agrupamento para Detecção de Zonas de Criminalidade: Subsídios à Segurança Pública em Belo Horizonte

Daniel E. Santos¹, Carlos A. Silva¹

¹Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais (IFMG)

danieliasantos.dev@protonmail.com, carlos.silva@ifmg.edu.br

Abstract. *The dynamic detection of crime hotspots is essential for public safety policies, but the well-known Kernel Density Estimation (KDE) presents operational limitations. This article compares unsupervised learning techniques (K-Means, K-Medoids, HAC, DBSCAN, and HDBSCAN) using 19,146 records of copper cable thefts in Belo Horizonte. The statistically validated results reveal practical trade-offs: HDBSCAN generates more concentrated and stable zones, whereas HAC captures more future events under broader coverage. The predictive decay analysis confirms the rapid obsolescence of static maps. We conclude that these methods offer interpretable tools that optimize tactical planning in public security departments, with direct implications for Digital Government and Smart Cities.*

Resumo. *A detecção dinâmica de hotspots criminais é essencial para políticas de segurança pública, mas a conhecida Estimativa de Densidade de Kernel (KDE) apresenta limitações operacionais. Este artigo compara técnicas de aprendizado não supervisionado (K-Means, K-Medoids, HAC, DBSCAN e HDBSCAN) utilizando 19.146 registros de furtos de cabos de cobre em Belo Horizonte. Os resultados, validados estatisticamente, revelam trade-offs práticos: o HDBSCAN gera zonas mais concentradas e estáveis, enquanto o HAC captura mais eventos futuros sob maior cobertura. A análise de decaimento preditivo confirma a rápida obsolescência de mapas estáticos. Conclui-se que esses métodos oferecem ferramentas interpretáveis que otimizam o planejamento tático em secretarias de segurança pública, com implicações diretas para o Governo Digital e Cidades Inteligentes.*

1. Introdução

A identificação de zonas quentes (*hotspots*) de criminalidade por meio de dados georreferenciados é um instrumento essencial para o planejamento tático e a alocação de recursos operacionais em segurança pública. A Estimativa de Densidade de Kernel (KDE), embora seja a abordagem mais adotada, apresenta limitações reconhecidas: depende de escolhas subjetivas de parâmetros e falha em capturar a evolução espaço-temporal dinâmica dos fenômenos criminais [Chainey et al. 2008]. Nesse cenário, os métodos de agrupamento não supervisionado, em particular os baseados em densidade, surgem como alternativas robustas. Eles são altamente apropriados para a análise geoespacial por identificarem *clusters* com formas arbitrárias e tratarem explicitamente o ruído e as

distribuições de densidade não uniformes, características inerentes aos dados criminais urbanos [Campello et al. 2015]. Contudo, como a qualidade interna do agrupamento nem sempre reflete utilidade operacional, este trabalho compara cinco técnicas para a detecção dinâmica de zonas de criminalidade em dados reais: K-Means, K-Medoids, Agrupamento Hierárquico Aglomerativo, DBSCAN e HDBSCAN. A avaliação integra métricas de seleção paramétrica, validação interna estrutural e desempenho preditivo operacional, medido pelo Índice de Precisão Preditiva (PAI) e pelo Índice de Eficiência Preditiva (PEI) [Chainey et al. 2008, Du and Ding 2023, Sadeghi 2025].

2. Trabalhos Relacionados

Entre os métodos para identificação de zonas quentes de criminalidade, a Estimativa de Densidade de Kernel (KDE) é a técnica mais amplamente adotada, dada sua simplicidade e capacidade de gerar representações visuais contínuas. Apesar do uso generalizado, várias limitações têm sido documentadas: o método é altamente sensível à seleção de largura de banda e de parâmetros de *kernel*, escolhidos heurísticamente e com impacto significativo nos padrões resultantes [Chainey et al. 2008, Kalinic and Krisp 2018]. Estudos comparativos indicam ainda que a KDE carece de garantias formais de significância estatística e pode falhar na captura de padrões de crimes persistentes, porém menos intensos, que são operacionalmente relevantes [Garcia et al. 2019].

Para lidar com essas limitações, abordagens alternativas baseadas em agrupamento têm sido cada vez mais exploradas, pois os métodos de agrupamento reúnem eventos com base em semelhanças espaciais, sem depender de limites espaciais predefinidos ou premissas de suavização. Técnicas baseadas em partição, como o K-Means e o K-Medoids, são frequentemente usadas devido à sua eficiência computacional e facilidade de implementação, mas assumem formas de *cluster* esféricas e densidades uniformes, premissas que raramente se sustentam em dados reais de crimes urbanos [Sadeghi 2025]. Métodos de agrupamento hierárquico oferecem melhor interpretabilidade por meio de estruturas de dendrograma, mas frequentemente sofrem com alto custo computacional e sensibilidade a métricas de distância e critérios de ligação [Baqir et al. 2020]. O uso de malhas regulares (*grids*) é outro paradigma existente [Andrade et al. 2025], mas introduz estrutura geométrica rígida, compartilhando limitações no tratamento de ruído e nas distribuições irregulares típicas de ambientes urbanos.

Métodos de agrupamento baseados em densidade ganharam destaque particular nesse contexto devido à sua capacidade de identificar *clusters* com formas arbitrárias, lidar explicitamente com ruído e adaptar-se a densidades heterogêneas. O DBSCAN, e sua extensão hierárquica HDBSCAN, demonstram desempenho superior em vários cenários de análise geoespacial e criminal quando comparados a abordagens baseadas em partição e hierárquicas, particularmente em ambientes urbanos complexos caracterizados por espaços irregulares [Baqir et al. 2020]. O HDBSCAN reduz ainda mais a sensibilidade à seleção de parâmetros ao construir uma hierarquia de *clusters* baseados em densidade e selecionar *clusters* estáveis automaticamente, tornando-o especialmente adequado para análise espacial de dados com ruído [Campello et al. 2015].

Além das abordagens puramente espaciais, vários estudos destacam a importância de incorporar a dimensão temporal na detecção de zonas de criminalidade, pois o uso de dados históricos em representações espaciais estáticas pode distorcer a lei-

tura das mudanças do crime ao longo do tempo [Robinson 2009]. Métodos baseados em estatísticas de varredura espacial [Kulldorff 1997], detecção de pontos de mudança [Bai and Perron 1998, Aminikhanghahi and Cook 2017] e processos pontuais autoexcitantes [Mohler et al. 2011] têm sido usados para modelar a evolução temporal do crime. Embora úteis, essas técnicas frequentemente envolvem modelos estatísticos complexos, o que pode dificultar sua interpretação, escalabilidade ou uso operacional.

Abordagens baseadas em agrupamento combinadas com segmentação temporal conciliam interpretabilidade e utilidade prática, mas ainda faltam estudos empíricos que comparem diferentes paradigmas sob condições experimentais consistentes, com métricas de qualidade interna e desempenho preditivo. Este trabalho examina esse problema ao avaliar técnicas representativas para a detecção dinâmica de zonas de criminalidade com dados espaço-temporais reais.

3. Dados e Definição do Problema

Conjunto de Dados e Área de Estudo

A análise experimental é conduzida usando um conjunto de dados reais compreendendo 19.146 registros válidos de furtos de cabos de cobre (Art. 155 do Código Penal Brasileiro) coletados na cidade de Belo Horizonte, Brasil, abrangendo o período de março de 2018 a dezembro de 2025. Cada registro contém coordenadas geográficas (WGS 84, EPSG:4326) e *timestamp*. São utilizadas exclusivamente coordenadas geográficas e marcações temporais (*timestamps*), a fim de isolar a dinâmica espaço-temporal do crime. O escopo central deste estudo é analisar e identificar padrões de surgimento, dissipação e deslocamento espaço-temporal de *hotspots*. Portanto, o objetivo é apontar onde, quando e como a mancha criminal se manifesta, de forma mais precisa e eficiente. Salienta-se que a base de dados não é oriunda de Boletins de Ocorrência (BOs) das polícias estaduais, mas sim de registros operacionais integrados do Centro de Operações da Prefeitura, Guarda Civil Municipal, Empresa de Transportes e Trânsito de Belo Horizonte (BHTrans) e operadoras de telefonia. O pré-processamento consistiu na extração de latitude, longitude e data/hora, seguido de higienização: remoção de dados faltantes, duplicatas exatas (mesma coordenada e carimbo de tempo) e coordenadas anômalas. Adicionalmente, aplicou-se um filtro de interseção espacial para excluir ocorrências registradas fora dos limites territoriais de Belo Horizonte. Além disso, o sistema de coordenadas dos registros foi reprojetoado para UTM Zona 23S (EPSG:31983) para compatibilização com o sistema de coordenadas padrão da PBH, com o propósito de viabilizar a análise dos dados com as ferramentas de georreferenciamento já existentes no município.

Embora a base compreenda registros de 2018 a 2025, a modelagem utilizou 2022–2024 para treinamento e 2025 para avaliação. Esse recorte prioriza registros mais recentes e consistentes, reduz o efeito de mudanças nos padrões espaço-temporais do fenômeno criminal, associadas a possível deriva conceitual (*concept drift*), e reserva 2025 para validação preditiva em dados não vistos. Além disso, devido às mudanças abruptas nas dinâmicas sociais em decorrência da pandemia de COVID-19, os dados do biênio 2020–2021 poderiam conter viés de anomalia, pois houve grande redução de atividades comerciais e circulação de pessoas em virtude dos diversos momentos de rigoroso *lock-down*. Nesse sentido, a restrição busca garantir que os dados de treinamento reflitam a dinâmica contemporânea do furto de cabos. Por fim, observa-se que a distribuição tem-

pela capacidade das regiões de *hotspot* derivadas dos *clusters* identificados na janela W_j de capturar eventos futuros em W_{j+1} , avaliada pelo Índice de Precisão Preditiva (PAI) e pelo Índice de Eficiência Preditiva (PEI) [Chainey et al. 2008, Du and Ding 2023]. A Estimativa de Densidade de Kernel é utilizada como linha de base para contextualizar os resultados dentro das práticas estabelecidas na análise criminal.

Limitações dos Dados e Considerações Éticas

Registros oficiais de ocorrências refletem crimes *reportados*, estando sujeitos à subnotificação e a vieses de policiamento: regiões com maior presença policial tendem a apresentar maiores taxas de registro [Mohler et al. 2011]. Além disso, o uso de modelos preditivos baseados em dados históricos para direcionar o policiamento levanta preocupações éticas relacionadas a *feedback loops*, nos quais o reforço do patrulhamento em *hotspots* pode amplificar os vieses existentes [Du and Ding 2023]. Neste trabalho, os registros utilizados não contêm identificação de vítimas ou suspeitos, e os resultados são apresentados de forma agregada como zonas de risco.


4. Metodologia

A metodologia adota um desenho comparativo em que múltiplas técnicas de agrupamento são aplicadas a dados criminais segmentados temporalmente e avaliadas por métricas de seleção de parâmetros, validade interna, desempenho preditivo e comparação com uma linha de base.

Visão Geral da Abordagem

A metodologia compreende três fases sequenciais, ilustradas na Figura 2: (i) pré-processamento e segmentação temporal dos dados criminais; (ii) aplicação dos algoritmos de agrupamento e das respectivas métricas de avaliação da qualidade interna para cada janela temporal; e (iii) avaliação preditiva comparativa com KDE como linha de base.

Figura 2. Processo de detecção e avaliação dinâmica de zonas de criminalidade.



Técnicas de Agrupamento

Cinco técnicas são avaliadas, representando distintos paradigmas: K-Means e K-Medoids (partição, assumem formas esféricas), Agrupamento Hierárquico Aglomerativo (hierarquia geométrica, sensível a critérios de ligação) [Sadeghi 2025, Baqir et al. 2020], DBSCAN e HDBSCAN (densidade, identificam formas arbitrárias e tratam ruído explicitamente). O HDBSCAN estende o DBSCAN construindo uma hierarquia de *clusters* e selecionando os agrupamentos estáveis automaticamente [Campello et al. 2015]. A

KDE é adotada como linha de base, gerando superfícies contínuas de intensidade de eventos para cada janela temporal com parâmetros consistentes [Chainey et al. 2008, Kalinic and Krisp 2018].

Seleção de Parâmetros

Os parâmetros de agrupamento são selecionados com base em práticas relatadas na literatura e em análises exploratórias preliminares do conjunto de dados. Para métodos baseados em partição, o número de *clusters* (k) é variado dentro de uma faixa razoável para avaliar a estabilidade [Sadeghi 2025]. Para métodos baseados em densidade, os parâmetros relacionados ao tamanho da vizinhança e à densidade mínima do *cluster* são ajustados para refletir a escala espacial dos eventos [Campello et al. 2015]. A mesma estratégia é aplicada consistentemente em todas as janelas temporais.

5. Avaliação Experimental

Os experimentos seguem um protocolo único aplicado a todas as técnicas: mesma extensão espacial, mesmo sistema de coordenadas e mesma divisão temporal. Essa uniformidade permite atribuir diferenças de desempenho às características de cada algoritmo, e não a variações na configuração experimental.

Configuração Experimental

Todos os experimentos são conduzidos usando o conjunto de dados segmentado temporalmente descrito na Seção 3. Cada técnica é aplicada independentemente a cada janela temporal seguindo a estratégia de seleção de parâmetros da Seção 4. Para reduzir o efeito da inicialização aleatória nos métodos particionais, foram realizadas múltiplas execuções, e os resultados foram agregados por médias. Os métodos baseados em densidade foram executados de forma determinística.

Os experimentos foram conduzidos em ambiente com processador com 8 cores a 4.8GHz, 32 GB de RAM, SO Debian GNU/Linux Bookworm, utilizando Python 3.11 em contêiner Docker com `scikit-learn` 1.4, `hdbscan` 0.8.33 e `scikit-learn-extra`. Para os métodos com inicialização aleatória, foi utilizada semente 42. Os tempos médios de execução do *pipeline* completo de otimização paramétrica e clusterização, para todas as granularidades temporais, foram: K-Means 33,98 s, K-Medoids 87,81 s, HAC 64,63 s, DBSCAN 226,54 s, HDBSCAN 20,98 s e KDE 38,51 s.

Métricas de Seleção e Validação do Agrupamento Interno

O agrupamento é avaliado sob duas perspectivas. As Métricas de Seleção (Cotovelo, BIC e K-distance) determinam a arquitetura ótima de cada algoritmo antes da geração dos agrupamentos. Para K-Means, K-Medoids e HAC, valores candidatos a k são submetidos às métricas de validação interna (Silhouette, Davies-Bouldin e Calinski-Harabasz), sendo escolhido o de melhor desempenho [Sadeghi 2025]. Para DBSCAN e HDBSCAN, métricas como Silhouette são inadequadas para agrupamentos de densidade, pois penalizam formas não convexas e ruído [Moulavi et al. 2014, Sadeghi 2025]; por isso, utiliza-se o DBCV para orientar a seleção dos parâmetros de vizinhança e tamanho mínimo de *cluster*, respeitando o limite de 30% de ruído [Schubert et al. 2017]. A Tabela 1 apresenta as métricas e parâmetros selecionados.

Tabela 1. Métricas de validação e parâmetros para os diferentes algoritmos de agrupamento.

Algoritmo	Parâmetros	Silhouette	Davies-Bouldin	Calinski-Harabasz	DBCV	Ruído (%)	# Clusters
K-Means	$k = 14$	0.393	0.822	16943.713	–	–	14
K-Medoids	$k = 7$	0.404	0.786	16551.933	–	–	7
HAC	$k = 5$	0.398	0.844	15071.423	–	–	5
DBSCAN	$min_samples = 23,$ $\varepsilon = 2.95e - 4$	–	–	–	inválido	0.015	1
HDBSCAN	$min_cluster_size = 5$	–	–	–	0.248	24.145	937

Avaliação da Precisão Preditiva

A utilidade operacional das zonas de criminalidade é avaliada usando o PAI e o PEI. O PAI mede a proporção de eventos futuros capturados nas regiões de *hotspots* em relação à cobertura espacial, sendo calculado a partir de uma janela temporal e avaliado na janela subsequente [Chainey et al. 2008]. O PEI avalia a capacidade do modelo de se aproximar da predição ótima teórica [Du and Ding 2023]. Formalmente, dado n_i = ocorrências capturadas na zona, n = total de ocorrências, a_i = área da zona e A = área total de estudo:

$$PAI = \frac{n_i/n}{a_i/A}, \quad PEI = \frac{PAI}{PAI_{opt}} \quad (1)$$

onde $PAI_{opt} = \min(1, n_i/n) \cdot (A/a_i)$ representa o PAI teórico ótimo para a cobertura a_i/A [Du and Ding 2023].

Na avaliação preditiva, os padrões estimados a partir dos dados de 2022–2024 foram confrontados com os eventos de 2025, mantidos como conjunto de teste temporal.

Comparação de Linha de Base

As abordagens de agrupamento são comparadas à KDE, com áreas de cobertura normalizadas para avaliação sob os mesmos protocolos de PAI e PEI [Chainey et al. 2008, Kalinic and Krisp 2018]. A Figura 3 e a Tabela 2 sintetizam os resultados preditivos por algoritmo e granularidade.




Figura 3. Comparativo dos resultados médios do PAI, PEI e Taxa de Acerto, por Algoritmo e Granularidade.

Tabela 2. Resultados médios e desvio padrão do PAI, PEI e Taxa de Acerto.

Modelo	Granularidade	PAI		PEI		Acerto (%)	
		Média	Desvio	Média	Desvio	Média	Desvio
HDBSCAN	Semanal	4.912	1.548	0.294	0.093	29.413	9.268
	Mensal	4.614	0.831	0.276	0.050	27.631	4.976
	Bimestral	4.608	0.748	0.276	0.045	27.592	4.481
	Trimestral	4.648	0.740	0.278	0.044	27.832	4.433
K-Means	Semanal	2.660	0.658	0.318	0.079	31.848	7.874
	Mensal	2.543	0.472	0.304	0.056	30.439	5.648
	Bimestral	2.622	0.304	0.314	0.036	31.384	3.643
	Trimestral	2.617	0.332	0.313	0.040	31.323	3.972
K-Medoids	Semanal	2.698	0.948	0.235	0.082	23.472	8.248
	Mensal	2.723	0.598	0.237	0.052	23.688	5.199
	Bimestral	2.688	0.489	0.234	0.043	23.384	4.253
	Trimestral	2.691	0.452	0.224	0.039	23.415	3.929
HAC (Ward)	Semanal	1.778	0.387	0.380	0.083	38.003	8.268
	Mensal	1.750	0.257	0.374	0.055	37.394	5.496
	Bimestral	1.729	0.155	0.369	0.033	36.949	3.315
	Trimestral	1.725	0.167	0.369	0.036	36.857	3.567
DBSCAN	Semanal	0.938	0.013	0.994	0.014	99.357	1.406
	Mensal	0.937	0.009	0.992	0.010	99.234	0.973
	Bimestral	0.937	0.008	0.992	0.008	99.213	0.838
	Trimestral	0.937	0.005	0.992	0.005	99.247	0.512
KDE	Semanal	5.665	3.212	0.093	0.053	9.326	5.288
	Mensal	5.220	2.350	0.086	0.039	8.593	3.870
	Bimestral	5.372	2.215	0.089	0.037	8.844	3.647
	Trimestral	5.398	1.995	0.096	0.042	8.887	3.284

6. Resultados e Discussão

Os resultados são analisados em duas dimensões: qualidade estrutural dos agrupamentos no período de treinamento e capacidade preditiva sobre dados não vistos (2025).

Qualidade do Agrupamento Interno

A Tabela 1 resume os parâmetros otimizados e as métricas de validação interna obtidas por cada técnica de agrupamento. Os métodos baseados em partição e hierarquia geométrica (K-Means, K-Medoids e HAC) apresentaram valores próximos de Silhouette (entre 0,39 e 0,40) e Davies-Bouldin. Ainda assim, o uso de distâncias euclidianas e de *clusters* aproximadamente esféricos levou esses algoritmos a dividir a cidade em poucas regiões amplas ($k = 14$ para K-Means e $k = 5$ para HAC). Esse tipo de representação é menos útil para fins táticos, pois não acompanha a distribuição espacial irregular associada à malha viária urbana. Entre os métodos baseados em densidade, o comportamento foi distinto. O DBSCAN clássico apresentou *chaining effect* (efeito de encadeamento), formando um único *cluster* contínuo que cobriu praticamente todo o conjunto de dados (com apenas 0,015% de ruído). Como esse resultado caracteriza um agrupamento degenerado, o DBCV foi tratado como inválido para fins de comparação, em vez de interpretado como medida de qualidade do agrupamento. Já o HDBSCAN filtrou 24,14% do ruído espacial e identificou 937 micro-zonas consistentes, com DBCV de 0,248, o maior valor entre os métodos baseados em densidade.

A capacidade de identificar *clusters* com forma arbitrária torna o HDBSCAN útil para uso tático, pois os *hotspots* identificados acompanham variações locais de densidade das ocorrências e são detectados sem exigir a definição prévia de seu número. Em

conjunto, os resultados da validação interna indicam que os métodos baseados em densidade representam melhor a distribuição irregular e ruidosa dos dados criminais espaço-temporais. Embora métricas como o DBCV tendam a superestimar o escore de micro-agrupamentos (ex.: pares de coordenadas), o espaço de busca do parâmetro tamanho mínimo do *cluster* (*mcs*) foi limitado ao intervalo [5,30]. Com isso, busca-se evitar que as zonas detectadas reflitam micro-eventos isolados, em vez de padrões recorrentes de crime.

Para avaliar a robustez da parametrização do HDBSCAN, realizou-se análise de sensibilidade variando `min_cluster_size` (*mcs*) em [3,30]: o DBCV manteve-se em [0,2165; 0,3613] e o número de *clusters* variou de 1.790 (*mcs* = 3) a 64 (*mcs* = 30). Adotou-se *mcs* = 5, que mantém o ruído em 24,15% e evita que os *hotspots* reflitam apenas micro-eventos isolados. Para o DBSCAN, variações de ϵ ($\pm 15\%$ em torno do valor ótimo) e de *min samples* em {15, 23, 30} produziram entre 1 e 3 *clusters*, confirmando a tendência do método a formar agrupamentos degenerados ou de baixa utilidade operacional diante de distribuições de densidade heterogênea.

Implicações para a Análise Dinâmica de Crimes

Os resultados preditivos resumidos na Tabela 2 não apontam um vencedor único: cada algoritmo viável ocupa uma posição distinta no espaço PAI–PEI. A utilidade operacional dos modelos foi avaliada sob a ótica preditiva estrita, utilizando os anos de 2022 a 2024 para a modelagem espacial e o ano de 2025 como cenário futuro de teste, limitando a envoltória de patrulhamento tático a 10% do território. A Tabela 2 indica que a relação entre concentração espacial e cobertura absoluta varia entre os algoritmos testados.

A KDE obteve os maiores valores absolutos de PAI (5,22 a 5,66), mas esse resultado está associado a áreas de cobertura muito pequenas. Em termos de acerto sobre eventos futuros, o método capturou menos de 10% das ocorrências. O DBSCAN, por sua vez, apresentou PAI inferior a 1,0 e taxa de acerto próxima a 99%, porque concentrou quase todo o território em um único *cluster*, o que reduz sua utilidade para aplicação prática.

Entre os métodos que produziram resultados úteis para a análise, observa-se uma diferença entre precisão espacial e cobertura absoluta. O HDBSCAN alcançou o maior PAI entre os métodos de agrupamento (média de 4,65 na granularidade trimestral), indicando maior concentração de crimes por unidade de área patrulhada. O HAC (Ward), por outro lado, apresentou a maior taxa de acerto absoluta ($\approx 37\%$) e o maior PEI ($\approx 0,37$), mas com PAI bem menor ($\approx 1,73$), o que indica cobertura de regiões mais amplas. Essa diferença está relacionada ao tipo de agrupamento produzido por cada método: o HAC gera poucos polígonos convexos e extensos ($k = 5$), enquanto o HDBSCAN produz 937 micro-zonas irregulares distribuídas ao longo da malha viária. A escolha entre os dois depende do contexto de uso: o HDBSCAN é mais indicado quando o patrulhamento é limitado e a precisão espacial é prioritária, enquanto o HAC pode ser mais adequado quando há maior capacidade de cobertura e o objetivo é maximizar o número total de crimes capturados.

Para verificar a significância estatística das diferenças, aplicou-se o teste de Friedman aos valores de PEI obtidos nas janelas temporais semanais de 2025, granularidade que oferece o maior número de janelas de comparação entre as analisadas ($n = 35$). O

DBSCAN foi excluído por seu resultado degenerado, e o teste foi complementado pelo pós-teste de Nemenyi. O teste de Friedman rejeitou a hipótese nula de igualdade entre os algoritmos ($\chi^2 = 93,3254$, $p = 2,59 \times 10^{-19}$). O teste de Nemenyi indicou diferença estatisticamente significativa entre HDBSCAN e KDE ($p = 7,33 \times 10^{-8}$) e entre HDBSCAN e HAC (Ward) ($p = 0,0166$), reforçando que a superioridade de cada abordagem depende da métrica operacional adotada.

Decaimento Preditivo e Dinâmica Temporal

A avaliação em múltiplas granularidades temporais (Figura 3) indica que o desempenho preditivo não se mantém estável ao longo do tempo. A análise dos desvios padrão aponta a presença de decaimento preditivo (*predictive decay*). No caso da KDE, o desvio padrão do PAI chega a 3,21 na granularidade semanal, o que sugere sensibilidade a mudanças espaciais de curto prazo. A Figura 4 ilustra esse comportamento em janelas trimestrais consecutivas de 2023–2024, com deslocamento e dissolução das manchas criminais.




Figura 4. Evolução trimestral das zonas de criminalidade (HDBSCAN) em Belo Horizonte (2024–2025), ilustrando a dinâmica espaço-temporal.

O HDBSCAN apresentou maior estabilidade ao longo do tempo. Ao mesmo tempo, a acurácia dos modelos diminui ao longo do ano de teste, indicando que a distribuição espacial do furto de cabos se altera. Por isso, mapas criminais estáticos tendem a perder utilidade com o tempo, o que reforça a necessidade de reprocessamento periódico em janelas bimestrais ou trimestrais para apoiar o direcionamento de viaturas e o planejamento tático de secretarias de segurança pública em ambientes de Cidades Inteligentes.

Implicações para Políticas de Segurança Pública e Governo Digital

O uso do HDBSCAN em sistemas de apoio à decisão em segurança pública apresenta implicações práticas diretas para gestores públicos. O *pipeline* completo foi concluído

em 20,98 s, viabilizando reprocessamento periódico automatizado em plataformas de análise de segurança pública. A granularidade bimestral ou trimestral, identificada como mais estável, sugere um ciclo de atualização adequado para secretarias de segurança pública, conciliando resposta às mudanças nos padrões criminais com estabilidade suficiente para orientar a alocação de viaturas e a definição de áreas de patrulhamento prioritário, contribuindo para a racionalização do gasto público. A adoção de registros oficiais de ocorrências como insumo está alinhada aos princípios da Lei de Acesso à Informação (LAI) e à agenda de governo aberto, enquanto a anonimização dos dados reforça a compatibilidade com a LGPD. Em municípios com plataformas de Cidades Inteligentes, a metodologia pode ser integrada a centrais de operações urbanas, permitindo a atualização automática dos mapas de risco a partir dos fluxos de dados existentes. Freitas et al. [Freitas et al. 2023] demonstraram a viabilidade de integrar dados de segurança pública em ambientes digitais de apoio à gestão governamental, e o presente trabalho complementa essa abordagem ao fornecer zonas de risco atualizadas dinamicamente.

7. Conclusão

Os experimentos com 19.146 registros reais de furtos de cabos de cobre em Belo Horizonte mostram que a escolha do algoritmo de agrupamento influencia diretamente a utilidade dos *hotspots* para análise criminal. A KDE, embora amplamente utilizada na literatura, apresentou PAI $\approx 5,4$ associado a áreas de cobertura muito pequenas, com captura inferior a 10% das ocorrências futuras.

Entre os métodos com resultados mais úteis para a análise, observou-se diferença entre precisão espacial e cobertura absoluta. O HDBSCAN apresentou PAI médio de 4,65 na granularidade trimestral, com 937 micro-zonas que acompanham a malha viária urbana, sendo mais adequado quando a cobertura de patrulhamento é restrita. O HAC (Ward), com $k = 5$ regiões amplas, alcançou taxa de acerto de $\approx 37\%$ e PEI $\approx 0,37$, sendo preferível quando o objetivo é ampliar a cobertura total de ocorrências.

A avaliação em múltiplas granularidades temporais mostrou que o desempenho preditivo se altera ao longo do tempo, reduzindo a utilidade de mapas estáticos. O tempo de reprocessamento do HDBSCAN (20,98 s) é compatível com ciclos de atualização automatizada em secretarias de segurança pública. Como trabalhos futuros, destacam-se a integração a plataformas de governo digital, a incorporação de variáveis contextuais como infraestrutura elétrica e indicadores socioeconômicos, e a aplicação a outras tipificações criminais e municípios brasileiros.

Uso de Inteligência Artificial Generativa

Claude (Anthropic) foi utilizado para auxílio na revisão linguística e estruturação do texto. A responsabilidade pelo conteúdo é integralmente dos autores humanos, em conformidade com o Código de Conduta da SBC. Todos os scripts e resultados estão disponíveis no GitHub¹, sob licença GNU GPL v3.0.

Referências

Aminikhanghahi, S. and Cook, D. J. (2017). A survey of methods for time series change point detection. *Knowledge and information systems*, 51(2):339–367.

¹<https://github.com/danieliasantos/lasdigov>

- Andrade, Y., Teodoro, G., Ferreira, R., and Rocha, L. (2025). Um framework para avaliação de modelos de previsão espaço-temporal de crimes. *Revista Eletrônica de Iniciação Científica em Computação*, 23:136–142.
- Bai, J. and Perron, P. (1998). Estimating and testing linear models with multiple structural changes. *Econometrica*, pages 47–78.
- Baqir, A., ul Rehman, S., Malik, S., ul Mustafa, F., and Ahmad, U. (2020). Evaluating the performance of hierarchical clustering algorithms to detect spatio-temporal crime hot-spots. In *2020 3rd International Conference on Computing, Mathematics and Engineering Technologies (iCoMET)*, pages 1–5. IEEE.
- Campello, R. J., Moulavi, D., Zimek, A., and Sander, J. (2015). Hierarchical density estimates for data clustering, visualization, and outlier detection. *ACM Transactions on Knowledge Discovery from Data (TKDD)*, 10(1):1–51.
- Chainey, S., Tompson, L., and Uhlig, S. (2008). The utility of hotspot mapping for predicting spatial patterns of crime. *Security journal*, 21(1):4–28.
- Du, Y. and Ding, N. (2023). A systematic review of multi-scale spatio-temporal crime prediction methods. *ISPRS international journal of geo-information*, 12(6):209.
- Freitas, J. B., Clarindo, J. P., and Aguiar, C. D. (2023). Ambiente de data warehousing espacial para tomada de decisão sobre dados de crimes. In *Simpósio Brasileiro de Banco de Dados (SBBD)*, pages 36–42. SBC.
- Garcia, G., Silveira, J., Poco, J., Paiva, A., Nery, M. B., Silva, C. T., Adorno, S., and Nonato, L. G. (2019). Crimanalyzer: Understanding crime patterns in São Paulo. *IEEE transactions on visualization and computer graphics*, 27(4):2313–2328.
- Kalinic, M. and Krisp, J. M. (2018). Kernel density estimation (kde) vs. hot-spot analysis—detecting criminal hot spots in the city of San Francisco. *Lund, Sweden*.
- Kulldorff, M. (1997). A spatial scan statistic. *Communications in Statistics-Theory and methods*, 26(6):1481–1496.
- Mohler, G. O., Short, M. B., Brantingham, P. J., Schoenberg, F. P., and Tita, G. E. (2011). Self-exciting point process modeling of crime. *Journal of the american statistical association*, 106(493):100–108.
- Moulavi, D., Jaskowiak, P. A., Campello, R. J., Zimek, A., and Sander, J. (2014). Density-based clustering validation. In *Proceedings of the 2014 SIAM international conference on data mining*, pages 839–847. SIAM.
- Robinson, W. S. (2009). Ecological correlations and the behavior of individuals. *International journal of epidemiology*, 38(2):337–341.
- Sadeghi, B. (2025). Clustering in geo-data science: Navigating uncertainty to select the most reliable method. *Ore Geology Reviews*, page 106591.
- Schubert, E., Sander, J., Ester, M., Kriegel, H. P., and Xu, X. (2017). DBSCAN revisited, revisited: why and how you should (still) use DBSCAN. *ACM Transactions on Database Systems (TODS)*, 42(3):1–21.