

# **CityGuardian: Uma ferramenta para monitorar mudanças em padrões de criminalidade nas Cidades Inteligentes**

**Manoel Flavio Leal<sup>1</sup>, Luiz Gomes-Jr<sup>1</sup>**

<sup>1</sup>Universidade Tecnológica Federal do Paraná (UTFPR) – Curitiba – Brazil

manoelleal@alunos.utfpr.edu.br, lcjunior@utfpr.edu.br

**Abstract.** *To combat high crime rates, Smart Cities use monitoring and support tools to support prevention actions. Analyzing where and when a crime occurred is the first step in understanding crime patterns. Sudden changes such as the COVID-19 pandemic show the importance of understanding a fact that has happened to support assertive decisions. In this paper, we present CityGuardian, a web tool that monitors criminal occurrences and alerts when it identifies changes in space-time patterns. It also allows exploring the data that caused these changes in its graphical interface.*

**Resumo.** *Para combater os altos índices de criminalidade, Cidades Inteligentes recorrem a ferramentas de monitoramento e suporte para subsidiar ações de prevenção. Analisar onde e quando um crime ocorreu é o primeiro passo para entender os padrões de criminalidade. Mudanças repentinas, como a pandemia da COVID-19, mostram a importância de entender um fato ocorrido para se tomar uma decisão assertiva. Neste artigo, apresentamos o CityGuardian, uma ferramenta web, que monitora as ocorrências criminais e alerta ao identificar alterações de padrões no espaço-tempo. Além disso, ela permite explorar em sua interface gráfica os dados que causaram essas alterações.*

## **1. Introdução**

A criminalidade é um problema de destaque, sobretudo em grandes cidades. A compreensão do problema bem como o uso de técnicas modernas de monitoramento e suporte a decisão são elementos importantes para cidades inteligentes.

Os índices de criminalidade são utilizados pelas forças de segurança pública no acompanhamento dos padrões de crimes, além de subsidiar decisões e ações de prevenção. Para que ocorra um crime, com base na teoria das atividades rotineiras, é necessário em um mesmo espaço-tempo a existência de uma vítima em potencial, do criminoso e a oportunidade do delito [Cohen and Felson 1979]. Analisar onde e quando um crime ocorreu é apenas o ponto de partida para compreender os padrões de criminalidade nas grandes cidades, pois cada tipo de crime apresenta uma dinâmica, além de outros fatores externos que podem alterar drasticamente qualquer comportamento padrão. Um exemplo disso foi a chegada da Pandemia da COVID-19, que alterou o comportamento dos crimes em várias cidades da Europa e América Latina [Nivette et al. 2021].

De acordo com [de Segurança Pública 2021], no primeiro semestre de 2020, o Brasil registrou redução dos crimes contra o patrimônio, com destaque para roubos a transeuntes com queda de 33%. Também houve queda de 9,6% nos registros em delegacias relacionados a violência doméstica. Já o tráfico de drogas apresentou aumento de 56,7% em apreensão de cocaína e 128,3% em maconha.

Este tipo de mudança repentina e expressiva deixa claro que a tomada de decisão dos gestores de segurança precisa ser, assertiva e embasada em métodos científicos. Ferramentas computacionais, sobretudo as que usam modelo de aprendizado baseado em dados, podem direcionar esforços para onde realmente é necessário. Muitas ferramentas e técnicas foram propostas nesta área, apresentando *hotspots* de crimes, evolução do crime no tempo, visuais interativos e modelos espaciais preditivos, [Garcia et al. 2019], [Garcia-Zanabria et al. 2020], [ToppiReddy et al. 2018]. Porém, há pouca ênfase em monitoramento de mudanças de padrão de crime, o que seria um elemento fundamental para a inteligência policial. Tal ferramenta seria capaz de alertar o investigador sobre uma mudança de padrão de comportamento de ocorrências de determinado tipo de crime, seja em termos temporais ou geográficos.

Dessa forma, o objetivo deste trabalho é apresentar a ferramenta, que monitora as ocorrências criminais e emite um alerta quando uma anomalia no padrão de determinado tipo de crime é detectada. Além disso, sua interface interativa com visualizações espaciais e temporais permite explorar os dados, auxiliando no entendimento da possível causa desta mudança de padrão. Os resultados apresentados neste trabalho são referentes aos dados de criminalidade da Cidade de Curitiba-PR entre o período de janeiro de 2016 e dezembro de 2020.

## 2. Trabalhos Relacionados

Existem vários estudos e propostas de ferramentas para explorar e compreender os padrões de crimes, com ferramentas interativas que permitem interações com mapas e diversos tipos de gráficos. Além disso, é possível destacar detecção de *hotspots* e predição de onde e quando ocorrerão novos crimes. Nesta seção descrevemos os conceitos fundamentais de detecção de anomalias e os principais trabalhos relacionados.

### 2.1. Detecção de anomalias

A anomalia é uma observação do fato estudado que se afasta das demais observações, levantando suspeitas sobre sua normalidade. Existem várias técnicas para detectar anomalias, algumas mais genéricas, outras de uso específico para determinados domínios de aplicação. O estudo realizado por [Chandola et al. 2009] catalogou vários tipos de problemas envolvendo detecção de anomalias e as respectivas técnicas utilizadas. Em ocorrências criminais, como casos de fraude, foram utilizadas técnicas de Estáticas Paramétricas, Perfis Estatísticos usando Histogramas, Redes Neurais e Detecção de *Clusters*.

Quando o objetivo é analisar anomalias nos dados ao longo do tempo, é necessário utilizar técnicas capazes de detectar anomalias em séries temporais. O estudo realizado por [Blázquez-García et al. 2021] apresenta uma revisão abrangente das técnicas existentes, além de propor uma metodologia para auxiliar na escolha da melhor técnica para cada tipo de problema.

No caso de anomalias geográficas, uma técnica utilizada é *Local Indicator of Spatial Association* - LISA, que permite estimar o índice de autocorrelação de uma região com os seus vizinhos. Seu resultado pode ser agrupado em quatro *clusters*, definidos pelo diagrama de espelhamento de Moran como: *High-High* (HH), *Low-Low* (LL), *High-Low* (HL) e *Low-High* (LH). A categoria HH indica que a região analisada possui um valor mais alto que o esperado, e está cercada por vizinhos que também apresentam valores

altos. A LL indica uma região que possui valores abaixo do esperado, e está cercado por vizinhos também com valores baixos, ou seja, estas duas categorias são as que apresentam maior autocorrelação. As categorias HL e LH são os *outliers*, pois apresentam uma baixa autocorrelação. A HL indica uma região acima do esperado, cercado por vizinhos com valores baixos. A LH uma região com valor abaixo do esperado, cercado de valores altos [Anselin 1995]. Um exemplo de região LH seria um bairro com uma baixa quantidade de ocorrências de crimes furto e roubo, porém com seus bairros vizinhos possuem com um valor alto.

O estudo de [Yang et al. 2021] utilizou o LISA, para identificar a existência de padrões locais de crime e a autocorrelação espacial estatisticamente significativa entre as regiões censitárias de Chicago. Também utilizou o *Spatial Point Pattern Test* - SPPT para identificar mudanças de padrões no espaço em diferentes intervalos de tempo em ocorrências criminais durante o período da pandemia da COVID-19.

## 2.2. Ferramentas para analisar e explorar padrões de crimes

O uso de identificação de *hotspots* é uma técnica bastante utilizada para identificar padrões de criminalidade. Uma *Non-negative matrix factorization* – NMF foi utilizada por [Garcia et al. 2019] que construíram uma ferramenta de análise visual com o objetivo de identificar *hotspots* associados ao comportamento dos crimes ao longo do tempo na Cidade de São Paulo. Com o objetivo detalhar a concentração de ocorrências criminais e analisar os seus padrões espaciais e temporais em uma escala no nível de rua, foi implementado no trabalho de [Garcia-Zanabria et al. 2020] a ferramenta Mirante, que fornece um conjunto de componentes visuais interativos permitindo ao usuário explorar *heatmaps* e séries temporais. Além de mapas interativos, outro ponto de destaque nas ferramentas de análise da criminalidade são os modelos preditivos. A ferramenta apresentada por [ToppiReddy et al. 2018] calcula a probabilidade de um crime ocorrer em determinado local utilizando o algoritmo K-Nearest Neighbour. A ferramenta ainda permite que o usuário navegue em mapas 3D para explorar as ocorrências criminais.

## 3. Metodologia

O *CityGuardian* é uma aplicação web, implementada na linguagem *Python*, que monitora continuamente mudanças em padrões de criminalidade por meio da análise de anomalias em séries temporais e dados geográficos. Como mostra a Figura 1, alerta por meio de e-mail o responsável quando alguma alteração é identificada. Além disso, o *CityGuardian* permite em sua interface gráfica uma análise exploratória dos padrões identificados por meio das visualizações dos dados no espaço-tempo.

### 3.1. Dados

Os dados utilizados são referentes às ocorrências criminais diárias registradas no município de Curitiba (data do fato, tipo do crime, bairro, latitude e longitude) para os crimes de furto, roubo, estelionato, violência doméstica e drogas (tráfico de drogas e drogas para consumo pessoal) no período entre janeiro de 2016 e dezembro de 2020. Os dados foram gentilmente cedidos pela Coordenadoria de Análise, Planejamento e Estatística – CAPE, da Secretaria da Segurança Pública do Paraná - SESP-PR, respeitando-se a confidencialidade da informação.

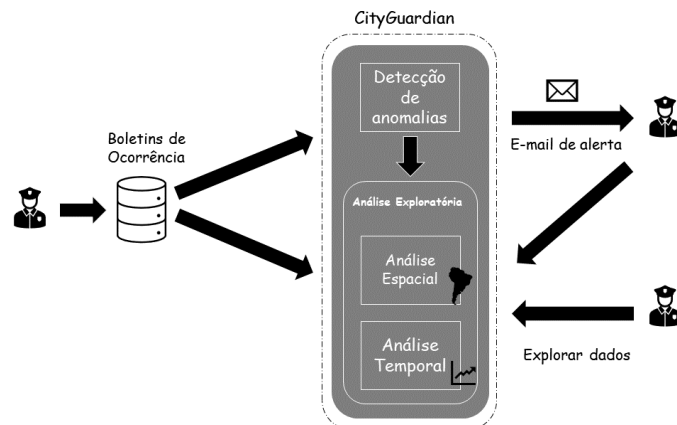


Figura 1. Arquitetura do *CityGuardian*

### 3.2. Alerta de anomalias

Uma rotina de agendamento executa a detecção de anomalias para cada um dos tipos de crime. Anomalias podem ser temporais ou geográficas. Caso ocorra uma anomalia, um alerta é enviado por e-mail. Após receber o alerta é possível visualizar no *CityGuardian* para analisar gráficos relacionados. A anomalia temporal é calculada com os valores das ocorrências ao longo do tempo utilizando a propriedade da distribuição Gaussiana [Chandola et al. 2009]. Foi considerado uma janela móvel de sete dias para o cálculo da média e do desvio padrão. O limite em relação a média móvel foi definido como 2 desvios padrão. Desse modo, cada média é comparada com os limites. Caso o valor exceda os limites, será definido como anomalia.

A anomalia geográfica consiste na aplicação da técnica LISA utilizando como variável de análise a taxa de variação de ocorrências em um intervalo de sete dias, para cada setor censitário de Curitiba. Em seguida classificamos os setores em *clusters* de acordo como diagrama de espalhamento de Moran. Deste conjunto selecionamos apenas os setores categorizadas como LH, ou seja, aqueles com baixa quantidade de ocorrências, porém com vizinhos com grande quantidade de ocorrências. Partimos da hipótese que nessas áreas possa ocorrer um deslocamento de ocorrências.

## 4. A Ferramenta *CityGuardian*

Nossa proposta difere das demais ferramentas apresentadas na seção 2.2. Essas focam na exploração de dados criminais no espaço-tempo e na predição de ocorrências, enquanto o *CityGuardian* parte da hipótese, que em uma cidade inteligente, o gestor de segurança pública precisa monitorar e receber alertas de mudanças de padrões tanto no tempo quando no espaço, para que possa tomar decisões assertivas embasado em métodos científicos. Neste contexto, destacamos o uso combinado da análise de anomalias em séries temporais e dados geográficos como uma vantagem no combate à criminalidade. As séries temporais abrangem toda a mudança de comportamento ao longo do tempo. Por outro lado, os dados geográficos permitem identificar anomalias espaciais como um deslocamento de ocorrências em uma região. Uma vez tendo o alerta é possível explorar os dados para entender o que causou este tipo de comportamento.

A seguir são apresentados os dados de criminalidade de Curitiba utilizando os principais componentes visuais da ferramenta.

#### 4.1. Visual Séries Temporais

Outra maneira de compreender o que ocorreu no tempo é por meio da visualização da decomposição da série temporal. A Figura 2 mostra a decomposição da série temporal furto e roubo entre o período de 2016 e 2020. Nota-se de forma clara a tendência de queda ao longo de todo período. Além da existência de picos e vales que se repetem a cada ano, evidenciando a existência de sazonalidade. Por outro lado, o componente resíduo apresenta um pico no início do ano de 2020, seguido por uma queda no mês de março e abril, período da publicação do decreto com medidas restritivas de mobilidade em Curitiba, o que indica uma mudança significativa no padrão da série comparada aos anos anteriores.

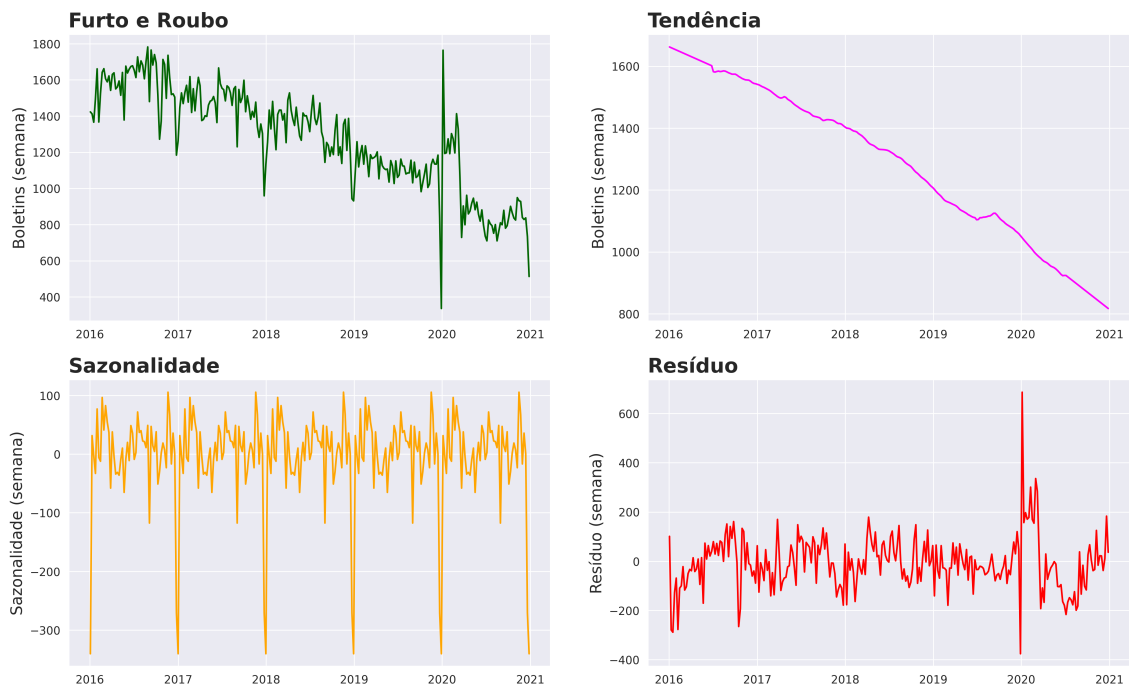


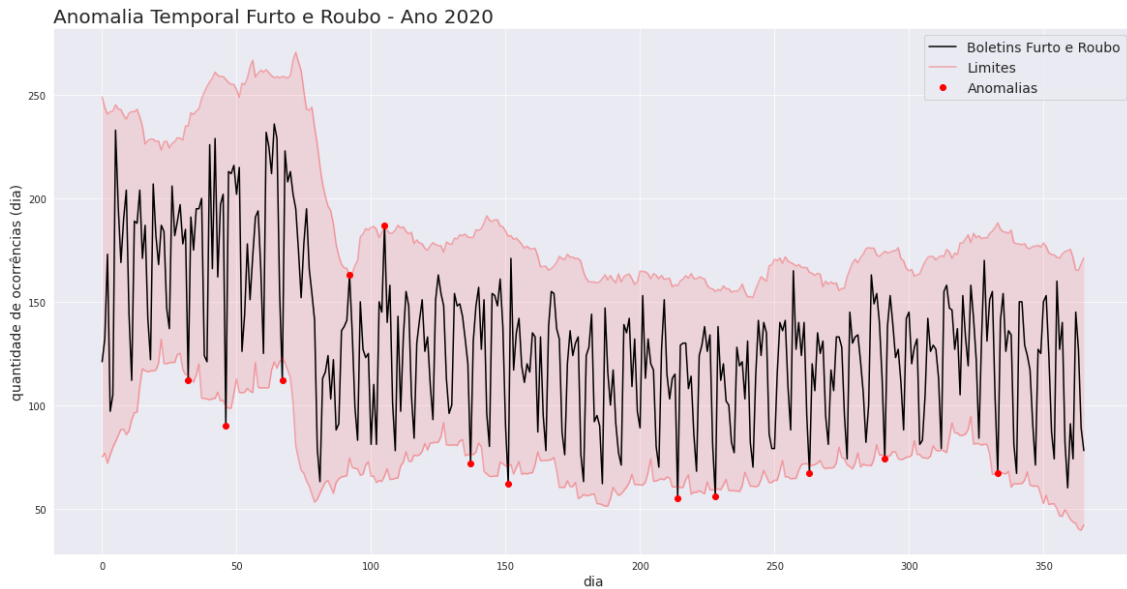
Figura 2. Visual de séries temporais para crimes de furto e roubo.

#### 4.2. Visual Alerta de Anomalia Temporal

É possível identificar as anomalias no gráfico de série temporal. A Figura 3 mostra as ocorrências de furto e roubo para o ano de 2020 em Curitiba. Note que os pontos em vermelhos são ocorrências detectadas como anomalias, indicando várias quedas durante o ano. A causa da queda está relacionada com o fato, que com menos pessoas transitando pelas ruas, comércio fechado e escolas paralisadas, existe uma menor probabilidade para ocorrências de furto e roubo. Além disso, as pessoas começaram a passar mais tempo dentro de suas casas, ou seja, menor chance de invasão para prática de furto e roubo.

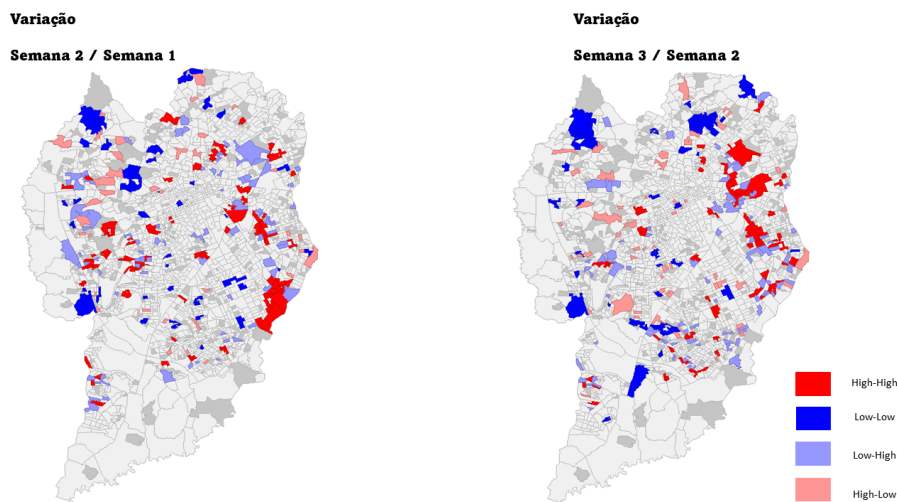
#### 4.3. Visual Alerta Anomalia Geográfica

A visualização dos *clusters* em mapas permite identificar como o crime está distribuído e as suas mudanças durante o tempo. Os crimes de furto e roubo foram os que apresentaram



**Figura 3. Alerta de anomalia temporal para crimes furto e roubo em 2020.**

a maior queda durante a pandemia da COVID-19. Além disso como é possível notar na Figura 4 a mudança na distribuição espacial. É possível notar nos dois períodos, que o crime acabou migrando para os bairros fora da região central e nas suas proximidades. Além disso é possível notar a mudança ao longo do tempo durante o ano de 2020. Nota-se que houve no segundo intervalo uma concentração na região leste da cidade onde se concentram vários bairros residenciais. Provavelmente impactados pelas medidas restritivas de mobilidade as pessoas acabaram por realizar suas atividades em seu bairro e nas redondezas.



**Figura 4. Alerta de anomalia geográfica para crimes de furto e roubo em 2020.**

## 5. Conclusão

O *CityGuardian* é uma ferramenta que apresenta grande potencial em auxiliar as forças de segurança pública em Cidades Inteligentes. Como demonstrado, apresentou resultados

pertinentes durante o seu uso com os dados referentes aos crimes ocorridos em Curitiba durante o período da Pandemia. Foram identificadas anomalias nas ocorrências de furto e roubo, apresentando constantes quedas durante todo o ano de 2020. Além disso, foi possível por meio da decomposição da série histórica identificar os padrões de sazonalidade e compará-los com o comportamento dos anos anteriores. Sobre os dados espaciais, foi possível identificar *clusters* autocorrelacionados e suas alterações durante o período. Isso demonstra a importância de identificar mudanças inesperadas. Um alerta mostrando uma alteração de um tipo de crime, pode apontar uma nova tendência, ou seja, isso pode auxiliar as forças policiais por exemplo, enviar uma patrulha onde foi sinalizado uma mudança ao invés de outro lugar apenas conhecido por ser violento.

Como trabalhos futuros temos: i - a construção de uma interface para gerenciar os usuários que receberão os alertas; ii - permitir a configuração dos limites inferior e superior na detecção de anomalias. Ainda em fase de análise, iii - envio do alerta por meio do *telegram* ou *whatsApp*, iv - implementar detecção de anomalias multivariadas.

## Referências

- Anselin, L. (1995). Local indicators of spatial association—*lisa*. *Geographical analysis*, 27(2):93–115.
- Blázquez-García, A., Conde, A., Mori, U., and Lozano, J. A. (2021). A review on outlier/anomaly detection in time series data. *ACM Computing Surveys (CSUR)*, 54(3):1–33.
- Chandola, V., Banerjee, A., and Kumar, V. (2009). Anomaly detection: A survey. *ACM computing surveys (CSUR)*, 41(3):1–58.
- Cohen, L. E. and Felson, M. (1979). Social change and crime rate trends: A routine activity approach. *American sociological review*, pages 588–608.
- de Segurança Pública, A. B. (2021). Fórum brasileiro de segurança pública, v. 14, 2020.
- Garcia, G., Silveira, J., Poco, J., Paiva, A., Nery, M. B., Silva, C. T., Adorno, S., and Nonato, L. G. (2019). Crimalyzer: Understanding crime patterns in são paulo. *IEEE Transactions on Visualization and Computer Graphics*, 27(4):2313–2328.
- Garcia-Zanabria, G., Gomez-Nieto, E., Silveira, J., Poco, J., Nery, M., Adorno, S., and Nonato, L. G. (2020). Mirante: A visualization tool for analyzing urban crimes. In *2020 33rd SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*, pages 148–155. IEEE.
- Nivette, A. E., Zahnow, R., Aguilar, R., Ahven, A., Amram, S., Ariel, B., Burbano, M. J. A., Astolfi, R., Baier, D., Bark, H.-M., et al. (2021). A global analysis of the impact of covid-19 stay-at-home restrictions on crime. *Nature Human Behaviour*, 5(7):868–877.
- ToppiReddy, H. K. R., Saini, B., and Mahajan, G. (2018). Crime prediction & monitoring framework based on spatial analysis. *Procedia computer science*, 132:696–705.
- Yang, M., Chen, Z., Zhou, M., Liang, X., and Bai, Z. (2021). The impact of covid-19 on crime: A spatial temporal analysis in chicago. *ISPRS International Journal of Geo-Information*, 10(3):152.