

ARTIGO

CARACTERIZAÇÃO TEMPORAL DE ROUBOS DE RUA CONTRASTANDO CONTEXTOS PRÉ-PANDÊMICO E PANDÊMICO

RENATO FIGUEIREDO FRADE

Graduado em Engenharia da Computação pela Universidade Federal de Itajubá (UNIFEI). Mestre em Ciência e Tecnologia da Computação (UNIFEI). Soldado especialista, desenvolvedor na área de comunicações, do Corpo de Bombeiros Militar de Minas Gerais (CBMMG).

País: Brasil **Estado:** Minas Gerais **Cidade:** Belo Horizonte

E-mail: renatoff10@hotmail.com **ORCID:** <https://orcid.org/0009-0006-9015-2850>

ERIC FERNANDES DE MELLO ARAUJO

Bacharel em Ciência da Computação pela Universidade Federal de Viçosa (UFV). Mestre em Ciência da Computação pela Universidade Federal de Minas Gerais (UFMG). Doutor em Ciência da Computação pela Vrije Universiteit, Holanda. Associate Professor, Calvin University, USA. Pesquisador em Modelagem de Comportamento e Sociologia Computacional.

País: USA **Estado:** Michigan (MI) **Cidade:** Grand Rapids

E-mail: eric.araujo@calvin.edu **ORCID:** <https://orcid.org/0000-0003-4263-9075>

JOÃO PAULO ROQUIM ROMANELLI

Bacharel em Matemática pela Universidade Federal de Minas Gerais (UFMG). Mestre em Matemática (UFMG). Doutor em Matemática pela Pontifícia Universidade Católica do Rio de Janeiro (PUC-RJ). Professor Associado da Universidade Federal de Itajubá (UNIFEI). Pesquisador em Métodos Numéricos para Equações Diferenciais Ordinárias e Aprendizado de Máquina.

País: Brasil **Estado:** Minas Gerais **Cidade:** Pouso Alegre

E-mail: joaoromanelli@unifei.edu.br **ORCID:** <https://orcid.org/0000-0002-4280-7350>

CARLOS HENRIQUE DA SILVEIRA

Bacharel em Ciência da Computação pela Universidade Federal de Minas Gerais (UFMG). Doutor em Bioinformática (UFMG). Professor Titular da Universidade Federal de Itajubá (UNIFEI). Coordenador do Grupo Interdisciplinar em Simulação e Inteligência Computacional (INSILICO). Pesquisador em Ciência dos Dados, Ciência das Redes e Inteligência Artificial.

País: Brasil **Estado:** Minas Gerais **Cidade:** Itabira

E-mail: carlos.silveira@unifei.edu.br **ORCID:** <https://orcid.org/0000-0001-6979-8469>

Contribuições dos autores: Renato Frade atuou na concepção, codificação, análise dos dados e redação do artigo; Eric Araujo atuou na concepção, análise dos dados, revisão do artigo, principalmente nos aspectos criminológicos; João Romanelli atuou na concepção, análise dos dados e revisão do artigo, principalmente nos aspectos matemáticos e estatísticos. Carlos Silveira atuou em todas as etapas: concepção, codificação, análise dos dados, redação e revisão final do artigo.

Agradecimentos: Gostaríamos de agradecer a parceria com a Polícia Militar de Minas Gerais (PMMG), especialmente pela cessão dos dados que fundamentaram este artigo.

RESUMO

Compreender a dinâmica das ocorrências de crimes é crucial para políticas mais eficazes de segurança pública. Este trabalho multidisciplinar visa à caracterização temporal de roubos de rua, sob contextos pré-pandêmicos e pandêmicos. Dados da Polícia Militar de MG de oito municípios mineiros foram consolidados em diferentes séries temporais: por hora, por dia, por dez dias e por mês. Foram utilizadas técnicas estatísticas, como análise espectral de frequências, autocorrelações e decomposições. Constatou-se uma queda média de 64% desse tipo de crime na pandemia. Foram encontradas evidências de regime estacionário nas séries pandêmicas, implicando ganho de maior aleatoriedade nas ocorrências. Independente se pré ou pandêmico, e contrariando o senso comum, a única sazonalidade detectada foi entre diurno/noturno, sendo indiferentes os dias da semana, se início ou fim de mês, ou os meses do ano. Este estudo apresenta vários insights para uma maior compreensão dos padrões temporais de crimes.

Palavras-chave: Roubos de rua. Séries temporais. Municípios mineiros. Pandemia de covid-19.

TEMPORAL CHARACTERIZATION OF STREET ROBBERIES CONTRASTING PRE-PANDEMIC AND PANDEMIC CONTEXTS

ABSTRACT

Understanding the dynamics of crime occurrences is crucial for more effective public security policies. This multidisciplinary study aimed at the temporal characterization of street robberies, under both pre-pandemic and pandemic contexts. Data from the Military Police of MG from 8 cities were consolidated into different time series: by hour, by day, every 10 days, and by month. Statistical techniques used were: spectral frequency analysis, autocorrelations, and decompositions. A 64% average decrease in this type of crime during the pandemic was observed. Evidence of a stationary regime in the pandemic series was found, implying a greater randomness in occurrences. Regardless of being pre or pandemic, and contrary to common sense, the only seasonality detected was between day/night, with the days of the week, the beginning or end of the month, or the months of the year being irrelevant. This study offers various insights for a better understanding of the temporal patterns of crimes.

Keywords: Time series. Street robberies. Municipalities of Minas Gerais (Brazil). Covid-19. Pandemic.

Data de recebimento: 20/10/2023 **Data de aprovação:** 14/01/2025

DOI: 10.31060/rbsp.2026.v20.n2.2081

INTRODUÇÃO

Compreender a evolução temporal de crimes é crucial para a formulação de políticas públicas e estratégias de segurança mais eficazes, especialmente em momentos de crises sociais severas, fornecendo informações valiosas sobre como eventos extraordinários podem afetar o comportamento humano e, conseqüentemente, a criminalidade.

A pandemia de Coronavirus Disease 2019 (covid-19), que teve início em dezembro de 2019, na China, rapidamente se transformou em uma crise global de proporções sem precedentes. A rápida disseminação

Caracterização temporal de roubos de rua contrastando contextos pré-pandêmico e pandêmico

Renato Figueiredo Frade, Eric Fernandes de Mello Araujo, João Paulo Roquim Romanelli e Carlos Henrique da Silveira

do *Severe Acute Respiratory Syndrome Coronavirus 2* (SARS-CoV-2) levou à implementação de medidas de isolamento social em todo o mundo, na tentativa de conter a propagação do vírus. Essas medidas restritivas desencadearam uma série de debates e preocupações, incluindo os potenciais efeitos na economia e na segurança pública (Atalan, 2020; Meyerowitz-Katz *et al.*, 2021; Hou *et al.*, 2022).

No entanto, o que se observou não foi exatamente o cenário de crise social previsto, revelando a importância de uma compreensão mais aprofundada dos fenômenos criminais em situações excepcionais. Nesse contexto, a pandemia tornou-se um “experimento natural” para criminologistas e pesquisadores interessados em entender o impacto das medidas restritivas na criminalidade. Sabe-se que as restrições de mobilidade e as mudanças nas rotinas cotidianas da população podem influenciar significativamente os padrões de crimes ao longo do tempo (Stickle; Felson, 2020; Oliveira, 2022).

Este artigo propõe mais uma contribuição nessa temática e tem como objetivo geral investigar as transformações nos roubos de rua ao longo do tempo, comparando períodos pré-pandêmicos e pandêmicos, em um conjunto de oito cidades mineiras: Alfenas, Itabira, Itajubá, João Monlevade, Lavras, Ouro Preto, São João Del Rei e Viçosa. A razão da escolha dessas cidades deveu-se aos dados disponibilizados pela Polícia Militar de Minas Gerais para este estudo. Objetivos específicos foram: realizar coleta e adequação dos dados; definir e aplicar os algoritmos mais apropriados às séries temporais concebidas; analisar e interpretar os resultados à luz de teorias pertinentes.

Duas perguntas principais nortearam esta pesquisa: Roubos de rua apresentam algum padrão temporal em diferentes escalas: horas do dia, dias da semana, dezenas nos meses, meses no ano? Esses padrões diferem quando comparamos períodos pré-pandêmicos e pandêmicos? Essas perguntas geraram, pois, as seguintes hipóteses de pesquisa: que os roubos de rua apresentam padrões temporais não aleatórios nas diferentes escalas delineadas; e que a pandemia alterou esses padrões.

Portanto, buscou-se identificar tendências, sazonalidades e outras mudanças na dinâmica desse tipo de crime, antes e durante a pandemia, através da análise de dados e da aplicação de técnicas estatísticas apropriadas às séries temporais criminais, como espectro de frequências, autocorrelações e decomposições. Essa integração de dados, técnicas e análises constitui a principal originalidade deste trabalho, seja em termos da abrangência das escalas temporais consideradas, seja no rigor matemático e estatístico adotado.

REFERENCIAL TEÓRICO

A compreensão das dinâmicas criminais tem sido um dos focos centrais da criminologia, com diversas teorias propostas para explicar a ocorrência de crimes em diferentes contextos e suas relações com fatores ambientais e sociais. Entre as teorias mais proeminentes na análise criminológica, destacam-se a Teoria da Atividade Rotineira (Cohen; Felson, 1979) e a Teoria dos Padrões de Crime (Brantingham; Brantingham, 2013), que abordam as circunstâncias e os padrões que facilitam a prática de crimes em determinados contextos. Além disso, com o avanço das ferramentas de simulação e análise computacional, métodos estatísticos e de ciência de dados têm sido amplamente utilizados para testar e validar essas teorias, fornecendo novas perspectivas para o estudo das interações entre criminosos, vítimas e ambiente urbano (Alves; Ribeiro; Rodrigues, 2018).

A Teoria da Atividade Rotineira, proposta por Cohen e Felson (1979), sugere que a ocorrência de crimes está intrinsecamente relacionada à convergência de três elementos essenciais: (1) um ofensor motivado, (2) uma vítima ou alvo atraente e (3) a ausência de um guardião capaz. Segundo essa teoria, crimes ocorrem quando esses elementos se encontram em tempo e espaço, formando um contexto fértil para a ação criminosa. A ausência de guardiões capazes – sejam eles pessoas, como policiais, ou mecanismos, como câmeras de segurança – aumenta as chances de sucesso de uma ação criminosa, já que diminui o risco percebido pelo ofensor.

No contexto do modelo abordado por Araújo e Gerritsen (2020), a Teoria da Atividade Rotineira foi utilizada para definir os padrões temporais de assaltos nas ruas. O modelo baseia-se na ideia de que a presença de ofensores e vítimas varia ao longo do dia, e a eficácia da simulação é alcançada ao incorporar dados reais para ajustar os parâmetros, conforme os padrões temporais observados na cidade de Lavras, Brasil.

A Teoria dos Padrões de Crime, desenvolvida por Brantingham e Brantingham (2013), oferece uma abordagem complementar para o estudo dos crimes, enfatizando que, embora o crime seja um fenômeno complexo, é possível identificar padrões em níveis diferentes, como localização e horários específicos. Segundo essa teoria, alguns locais apresentam características que os tornam mais suscetíveis a determinados tipos de crime. Esses locais, conhecidos como “pontos quentes” (*hot spots*), atraem ofensores devido a uma combinação de fatores, como acessibilidade, atividades econômicas e ausência de mecanismos de controle.

A Modelagem Baseada em Agentes (ABM) tem se consolidado como uma ferramenta valiosa para o estudo de fenômenos complexos em criminologia, como a dinâmica de crimes urbanos. Essa abordagem permite simular cenários realistas, nos quais agentes – representando criminosos e vítimas – tomam decisões baseadas em suas rotinas, motivações e percepções do ambiente. Groff (2007), ao utilizar a ABM para testar a Teoria da Atividade Rotineira, evidenciou que a simulação é eficaz para replicar o comportamento criminal em contextos variados e permite explorar intervenções preventivas em ambientes simulados.

TRABALHOS RELACIONADOS

Uma extensa revisão da literatura sobre a influência da pandemia nos índices de criminalidade em vários países pode ser consultada em Oliveira (2022). O autor encontrou, inicialmente, mais de 100 artigos e, após cuidadosa triagem, ficaram para revisão 33 publicações de nove países: Austrália, Canadá, China, Estados Unidos, Índia, Peru, Reino Unido e Suécia. De forma geral, essa revisão conclui que as medidas de restrição de mobilidade adotadas durante a pandemia da covid-19 tiveram um impacto significativo na dinâmica da criminalidade. Crimes contra o patrimônio, como furtos e roubos, apresentaram reduções expressivas, atribuídas à menor circulação de pessoas em espaços públicos e à maior presença de moradores em casa, o que aumentou a vigilância em áreas residenciais. Em contraste, homicídios, sequestros e extorsões, especialmente aqueles relacionados ao crime organizado, demonstraram menor sensibilidade às mudanças na mobilidade populacional, mantendo padrões relativamente estáveis. Já os crimes cibernéticos registraram aumento notável, refletindo o maior uso de tecnologias digitais para atividades cotidianas, como trabalho remoto, ensino à distância e comércio eletrônico.

Uma revisão integrativa da literatura feita por Ribeiro (2022) selecionou 12 artigos relacionados à violência e criminalidade durante a pandemia no Brasil. Genericamente, e sem entrar em detalhes quantitativos, concluiu que os artigos indicavam que o isolamento social intensificou a violência doméstica, especialmente contra mulheres, crianças, adolescentes e idosos, devido à convivência prolongada

Caracterização temporal de roubos de rua contrastando contextos pré-pandêmico e pandêmico

Renato Figueiredo Frade, Eric Fernandes de Mello Araujo, João Paulo Roquim Romanelli e Carlos Henrique da Silveira

com agressores. Houve também aumento no narcotráfico, ameaças a pesquisadores e violência digital envolvendo crianças e adolescentes. Por outro lado, observou-se redução de lesões por acidentes de trânsito e violência escolar.

No Brasil, são encontradas também algumas análises regionalizadas da relação crime x pandemia, a exemplo das conduzidas com dados dos estados do Rio de Janeiro (Monteiro; Carvalho; Gomes, 2021), do Ceará (Virgílio *et al.*, 2022), do Rio Grande do Norte (Castro *et al.*, 2021) e da cidade de Curitiba (Leal; Gomes Junior, 2022). Destaca-se ainda análise da correlação entre criminalidade violenta e pandemia em vinte municípios do Sul de Minas Gerais (Alves, 2022).

No estado do Rio de Janeiro, Monteiro, Carvalho e Gomes (2021) compararam os registros de diversos tipos de crimes, conforme dados do Instituto de Segurança Pública do Estado do Rio de Janeiro (ISP-RJ), no período de janeiro de 2016 a junho de 2020. Esses dados foram padronizados por Z-score e as medidas de variação dadas em unidades de desvios-padrão (dp). Um evento que se encontra a mais 2 dp abaixo ou acima da média é considerado incomum, com uma probabilidade de ocorrência inferior a 5% em condições normais, assumindo uma distribuição normal dos dados. Os autores constataram que crimes contra o patrimônio, como roubos de rua, de veículos e a residências tiveram quedas de, respectivamente: mais de 2 dp (abril e maio de 2020), 2,5 dp (maio de 2020) e 2,8 dp (junho de 2020). Também tiveram redução acima de 2 dp: homicídios dolosos e latrocínios, lesão corporal e estupro. Uma exceção foram os crimes de estelionato, com um aumento expressivo de 3,4 dp acima da média histórica. Os autores também cruzaram dados de circulação de pessoas fornecidos pela empresa Cyberlabs, aferidos por câmeras espalhadas em algumas regiões da cidade do Rio de Janeiro. Encontraram um coeficiente de correlação de 0,73 entre variação no fluxo de pessoas e a variação nos roubos de rua, reforçando a hipótese de que crimes de rua são fortemente dependentes da presença física de alvos e oportunidades.

No estado do Ceará, Virgílio *et al.* (2022) analisaram apenas os crimes de homicídios, no período de 2017 a 2020, conforme dados do Sistema de Informação sobre Mortalidade (SIM), do Datasus. Constataram que após uma redução de 2017 a 2019, as taxas de homicídio por 100.000 habitantes voltaram a subir em 2020 (65%), ano do início da pandemia no Brasil. Entre os fatores que podem ter contribuído para esse aumento, destacaram: greve na PM no início de 2020, soltura de detentos, agravamento das condições socioeconômicas e redução das forças policiais pela contaminação por covid-19.

Também comparando somente homicídios, mas no estado do Rio Grande do Norte, cruzando dados de diferentes fontes, entre 2019 e 2020, Castro *et al.* (2021) identificaram aumento de homicídios dolosos em 13,7%, mas redução de feminicídios em 38% e de lesões corporais seguidas de morte de 55,4% .

Já na cidade de Curitiba, Leal e Gomes Junior (2022) investigaram o impacto das medidas de distanciamento social nos padrões de diversos tipos de crimes, entre janeiro de 2016 a dezembro de 2020, a partir de dados fornecidos pela Secretaria da Segurança Pública do Paraná (Sesp-PR). Utilizaram a técnica de decomposição da série temporal de crimes para calcular um valor esperado em contraste com os valores reais. Os autores evidenciaram as seguintes variações nas ocorrências, em relação ao valor esperado: furto e roubo: 6,78% menor; estelionato: 10,72% maior; violência doméstica: 0,59% maior; e crimes relacionados a drogas: 3,53% maior. Fizeram uso também de modelos de regressão linear, tendo por variáveis explicativas: mês do ano, dia da semana, e dois índices: de rigidez, construído a partir de medidas governamentais restritivas; e de permanência residencial, aferido pelo Google. Essa análise de regressão indicou que furtos e roubos tiveram coeficiente de determinação alto (R2 próximos de 80%) para ambos

os índices, reforçando a hipótese de que foi a adesão ao isolamento social que teve maior impacto na redução desses crimes em Curitiba.

Alves (2022) estudou a influência do isolamento social durante a pandemia da covid-19 sobre as taxas de criminalidade violenta em vinte municípios do Sul de Minas Gerais, agrupados entre cidades pequenas e médias, entre janeiro de 2018 a 4 de abril de 2021. O autor constatou: redução média geral de 25,65% nesses tipos de crimes, sendo uma redução maior nas cidades médias (34,30%) que nas pequenas (17,00%); que cidades com maior adesão ao isolamento, como Poços de Caldas, tiveram reduções maiores; e que locais com baixa adesão, como Varginha, registraram estabilidade ou aumento nos crimes violentos.

METODOLOGIA

CONJUNTO DE DADOS

Os dados foram provenientes de Boletins de Ocorrência (BOs) registrados nos anos anteriores e durante a pandemia, pela PMMG. São referentes, especificamente, a crimes de roubos de rua, tipificados no art. 157 do Código Penal Brasileiro (Brasil, 1940). Doravante, qualquer uso da palavra crime neste artigo, quando não definido, refere-se a esse tipo, especificamente. Foram analisados somente esse tipo de crime em função dos dados disponibilizados pela PMMG.

A tabela com os dados brutos era formada por 9.274 linhas e 36 atributos, contendo crimes registrados entre 1º de janeiro de 2014 e 29 de março de 2022, numa amostra de oito municípios do interior de Minas Gerais, todos com aproximadamente 100 mil habitantes, a saber: Alfenas, Itabira, Itajubá, João Monlevade, Lavras, Ouro Preto, São João Del Rei e Viçosa.

Além da coluna Município, dentre os 36 atributos, havia aqueles descrevendo: data e hora do fato, dia da semana, dezena do mês, resultado, meio utilizado, tipo local, causa presumida e outros. Este artigo focou apenas no levantamento de padrões temporais, sem relacioná-los a nenhum outro fato complementar. Isso foi deixado para estudos futuros.

ADEQUAÇÃO DOS DADOS

Os dados brutos foram transformados a fim de gerar séries temporais, em diferentes escalas de tempo. Essas novas tabelas de apenas duas colunas contêm um atributo temporal e atributos de contagem ou média de crimes por unidade de tempo. As séries temporais analisadas foram:

- nHora: número de ocorrências consolidadas em 72.240 horas;
- nDia: número de ocorrências consolidadas em 3.010 dias;
- nDez: média de ocorrências em 10 dias do mês, dividindo o mês em três dezenas, totalizando 297 dezenas;
- nMês: média de ocorrências mensais consolidadas em 99 meses;

Caracterização temporal de roubos de rua contrastando contextos pré-pandêmico e pandêmico

Renato Figueiredo Frade, Eric Fernandes de Mello Araujo, João Paulo Roquim Romanelli e Carlos Henrique da Silveira

Foram imputados dados com zero crimes na base para que as séries temporais tivessem uma taxa de amostragem uniforme, ou seja, para que determinados intervalos de tempo sem ocorrências de crimes não fossem excluídos das análises.

ESCOLHA DOS ALGORITMOS

A ocorrência de crimes, principalmente nas escalas de horas e dias, tende a ser muito esparsa, muitas vezes sem registro de ocorrências em longas sequências de tempo, o que torna a série temporal “inflada em zeros” (Zhu, 2012). Tanta esparsidade pode esconder ou tornar difícil uma identificação confiável de padrões temporais. Outro ponto importante é que os dados de crimes são “contagens” no tempo, gerando uma matriz discreta de dados, com números inteiros de eventos. Tais características impõem restrições sobre quais modelos e ferramentas utilizar na análise desse tipo de série temporal (Green, 2021).

Neste artigo, tomou-se o devido cuidado de verificar se as modelagens e os algoritmos eram compatíveis com séries temporais esparsas e discretas no número de eventos, como foi o caso para nHora e nDia. Tal restrição arrefeceu-se em escalas de tempo maiores, em que a esparsidade diminuiu ou mesmo desapareceu, e pôde-se trabalhar com a média de eventos, como em nDez e nMês.

PANDEMIA DE COVID-19 E DIVISÃO DE PERÍODOS

Os dados de crimes disponíveis nesta análise cobriram uma parte da pandemia de covid-19 que tomou conta do planeta a partir de 2020, provocada pelo vírus SARS-Cov-2. A Organização Mundial da Saúde (OMS) declarou emergência de saúde pública de importância internacional em 30 de janeiro de 2020, e reconheceu oficialmente como uma pandemia em 11 de março de 2020 (WHO, 2023). O Brasil confirmou seu primeiro caso de covid-19 em 26 de fevereiro de 2020 (Lobo *et al.*, 2020), e o Ministério da Saúde declarou estado de transmissão comunitária em 20 de março de 2020 (Valent, 2020). Boa parte das cidades em Minas Gerais entraram em confinamento seletivo a partir dessa data, como Itabira, pelo Decreto Municipal 3.178/20 (Itabira, 2020). Portanto, para efeito de análises da influência da pandemia sobre os dados de crimes, neste artigo será considerada a data de 20 de março de 2020. Foi considerado também um período pré-pandêmico com mesmo número de horas do período pandêmico, conforme pode ser visto na Tabela 1.

PERIODOGRAMAS

Uma forma recorrente na literatura de sondar padrões em séries temporais é através de periodogramas, utilizados principalmente para identificar componentes periódicos (Stoica; Moses, 2005). Mais especificamente, ele estima a *Power Spectral Density* (PSD) média desses sinais, que no caso discreto pode ser calculada por técnicas envolvendo *Discrete-Time Fourier Transform* (DTFT). Assim, a PSD consegue identificar as frequências com maiores potências ou forças (*powers*) médias; grosso modo, aquelas com maior destaque na constituição de uma série temporal.

No entanto, é sabido que métodos clássicos de estimação da PSD por transformadas de Fourier apresentam sérias limitações, entre elas: exige o pressuposto de uma série temporal estacionária; sensibilidade a ruídos; a PSD estimada pode apresentar viés, uma vez que sua variância não fica assintoticamente a zero

quando o número de amostras cresce; e mesmo com um viés não acentuado, a PSD estimada pode apresentar alta variância (Stoica; Moses, 2005).

Uma alternativa para mitigar tais limitações é o uso da técnica *Multiple Taper Spectral Analysis* (MTSA) (Riedel; Sidorenko, 1995). Numa MTSA, múltiplas funções *tapers* (funções envolvendo janelas temporais) são aplicadas ao sinal original antes de serem entrada nas transformadas de Fourier. Esse pré-tratamento por funções *tapers* têm por objetivo operar uma composição de pesos sobre o sinal de entrada, de modo a dar mais ênfase aos padrões de frequência que possam ser mais relevantes e, assim, conter melhor os ruídos, e diminuir o viés e a variância da PSD média que será estimada. Por operar por janelas, o pressuposto de estacionariedade é enfraquecido.

Para as estimativas do intervalo de confiança das PSD médias no MTSA, foi adotado o método de reamostragem *Jackknife* (Efron, 1980). Esse método omite uma observação em N amostragens na estimativa de parâmetros, sendo N o número de observáveis. O *Jackknife* é o método de reamostragem que vem junto com o pacote R utilizado no cálculo do MTSA.

FUNÇÕES DE AUTOCORRELAÇÕES

Dado um processo estocástico representado pela realização de uma variável aleatória X_t no tempo t , a autocorrelação diz da correlação cruzada de seus valores consigo mesmos. Ou ainda, das correlações (geralmente Pearson) entre os valores no tempo t , e t mais um deslocamento temporal h ($t+h$), para qualquer inteiro t e h .

Neste trabalho, fez-se uso das seguintes funções de autocorrelação, como definidas em Shumway e Stoffer (2016):

Autocorrelation Function (ACF)

$$ACF(X, t, h) = \text{Cor}(X_t, X_{t+h}) \quad (1)$$

Ou seja, ACF verifica as correlações par a par na TS nos tempos t e $t+h$.

Partial Autocorrelation Function (PACF)

$$PACF(X, t, h) = \text{Cor} \left(X_t - \hat{X}_t, X_{t+h} - \hat{X}_{t+h} \right) \quad (2)$$

Onde:

$$\hat{X}_t = \beta_1 X_{t+1} + \beta_2 X_{t+2} + \beta_3 X_{t+3} + \dots + \beta_{h-1} X_{t+h-1} \quad (3)$$

$$\hat{X}_{t+h} = \beta_1 X_{t+h-1} + \beta_2 X_{t+h-2} + \beta_3 X_{t+h-3} + \dots + \beta_{h-1} X_{t+1} \quad (4)$$

Ou seja, PACF elimina as dependências lineares que pode haver entre X_t e X_{t+h} , computando uma correlação mais “pura” entre ambos.

DECOMPOSIÇÃO

Séries temporais podem apresentar alguns padrões intrínsecos interessantes, tais como: tendências, ciclos e sazonalidades. Tendências indicam as variações de mais longo prazo, tais como crescimentos e decaimentos. Já ciclos e sazonalidades indicam flutuações de mais curto prazo, sendo a diferença, basicamente, que nos ciclos as flutuações são aperiódicas, enquanto nas sazonalidades elas ocorrem em frequências/períodos fixos. Existem vários métodos capazes de decompor uma série temporal conforme esses padrões, sendo o mais comum a decomposição em: Tendências-Ciclos (T), Sazonalidades (S) e o Resíduo-Ruído (R), tal qual na fórmula (Hyndman; Athanasopoulos, 2021):

$$Y_t = T_t + S_t + R_t \quad (5)$$

É possível medir a força ou importância (*strength*) das componentes T e S pelas equações:

$$F_T = \left(0, 1 - \frac{\text{var}(R_t)}{\text{var}(T_t + R_t)} \right) \quad (6)$$

$$F_S = \left(0, 1 - \frac{\text{var}(R_t)}{\text{var}(S_t + R_t)} \right) \quad (7)$$

Claramente, se a contribuição da componente T for pequena, $\text{var}(R)$ e $\text{var}(T+R)$ terão valores muito próximos, e F_T tenderá a 0; caso contrário, estará perto de 1. Da mesma forma, se a contribuição da sazonalidade for pequena, $\text{var}(R)$ e $\text{var}(S+R)$ terão valores similares, e F_S tenderá a 0; caso contrário, perto de 1. Assim, quanto mais próximos F_T e F_S ficarem de 1, maiores suas contribuições; e perto de 0, o oposto.

Neste trabalho, utilizou-se o método de *Seasonal and Trend decomposition using LOESS* (STL), em que *Locally Estimated Scatterplot Smoothing* (LOESS) é um método de regressão não linear, não paramétrico, a partir de interpolações polinomiais locais em segmentos de dados (Cleveland *et al.*, 1990). A decomposição STL apresenta várias vantagens (Hyndman; Athanasopoulos, 2021), entre elas:

Ser capaz de lidar com qualquer tipo de sazonalidade, independente da unidade temporal;

Permitir que a componente sazonal seja variável no tempo;

Admitir parâmetros para controlar a suavidade (*smoothness*) da componente tendência-ciclo;

Ser robusta a valores extremos (*outliers*).

IMPLEMENTAÇÃO

A ciência dos dados desenvolvida neste trabalho foi feita na Linguagem de Programação R, (R version 4.2.2 Patched [2022-11-10 r83330]), com o ambiente de desenvolvimento Rstudio (2023.06.0 Build 421). Detalhes das funções, parametrizações e pacotes utilizados encontram-se no Quadro I do Apêndice A.

RESULTADOS E DISCUSSÕES

Resultados e discussões são apresentados de forma integrada, para uma melhor compreensão e análise.

RESUMO CONSOLIDADO POR PERÍODO

A Tabela 1 mostra um consolidado por período da série temporal nHora, conforme os períodos Total, pré-pandêmico e pandêmico. O período Total compreendeu 9.274 crimes em 72.240 horas, com média de 1 crime a cada 8 horas. O período pré-pandêmico e pandêmico registrou 1.903 e 678 ocorrências, respectivamente, para um mesmo número de 17.760 horas. Houve uma queda de aproximadamente 64% (quase 3 vezes menor) no número de crimes entre esses dois períodos, passando da média de 1 crime a cada 9 horas para 1 crime a cada 26 horas.

TABELA 1

Resumo da tabela nHora consolidado por períodos

PERÍODO	INTERVALO	HORAS	DIAS	ANOS	CRIMES	HORAS/CRIME	DIAS/CRIME
TOTAL	2014-01-01 – 2022-03-29	72.240	3.009	8,24	9.274	8	0,32
PRÉ-PANDÊMICO	2018-03-11 – 2020-03-19	17.760	739	2,02	1.903	9	0,39
PANDÊMICO	2020-03-20 – 2022-03-29	17.760	739	2,02	678	26	1,09

Fonte: Elaborada pelos autores, com base em dados da Polícia Militar de Minas Gerais (PMMG).

SÉRIE TEMPORAL DE CRIMES POR HORA

A primeira das séries temporais analisada foi a nHora, que registra crimes por hora. Constitui a série temporal com a menor granularidade neste estudo, ou seja, que geraram as mais altas frequências de ocorrências.

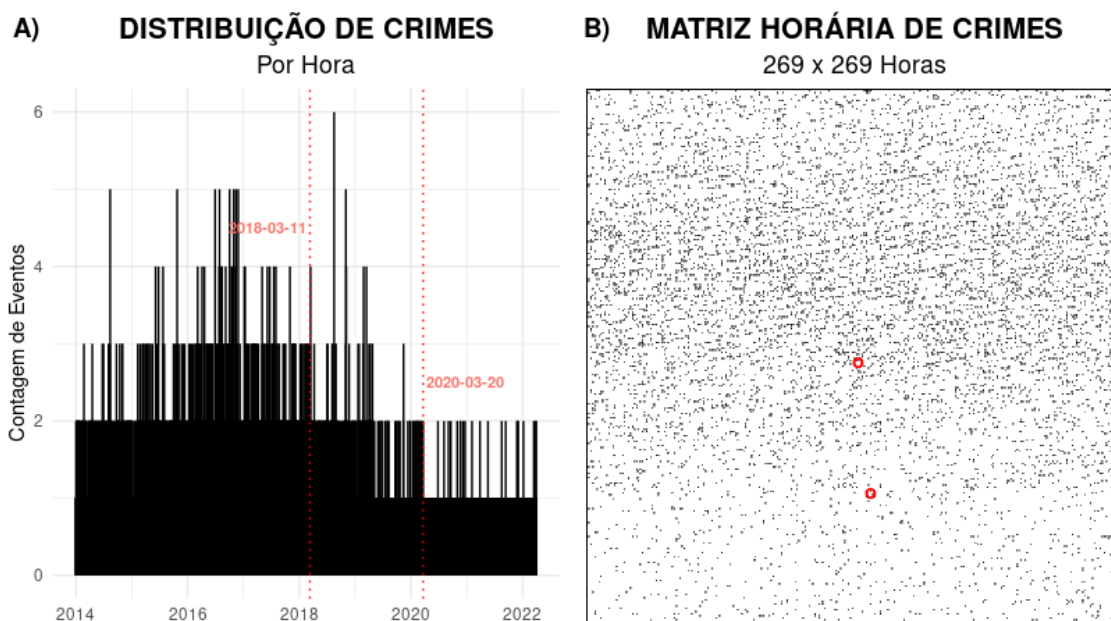
A Figura 1 mostra o perfil da série temporal nHora em duas visualizações distintas. Na Figura 1-A vê-se a série temporal como um vetor de contagem de eventos indexados no tempo. O primeiro termo da série começa em 2014-01-01 00:00:00 e o último em 2022-03-29 23:00:00. Percebe-se alguns padrões: o perfil segue uma distribuição discreta côncava, que cresce a partir de 2014, atinge um modal entre 2016 e 2017, e decresce a partir de 2018, estabilizando-se de 2020 em diante. Contribui para essa estabilidade uma mudança no padrão de ocorrências por volta da data assumida neste trabalho como o início da pandemia: 2020-03-20.

A Figura 1-B é uma forma de visualizar a esparsidade das ocorrências de crimes no período estudado. A série temporal nHora foi dobrada numa matriz quadrada de 269 x 269 horas, com as posições de horas começando na célula superior à esquerda, seguindo à direita e abaixo, em zigue-zague até fechar a matriz quadrada. A diferença entre $269 \times 269 = 72.361$ e 72.240 foi preenchida com zeros ao final. Os pontos vermelhos demarcam o início do período pré-pandêmico e pandêmico. Percebe-se que os eventos de crimes ocorrem de forma bem esparsa ao longo das horas. Das 72.240 horas da nHora, em apenas 7.777 ocorreram crimes, algo perto de 11%. Ou seja, quase 90% da matriz é composta de zeros. Mas essa es-

parsidade não é homogênea. Os pontos ganham intensidade quando se aproximam da região central da matriz (2017), mas ficam bem mais esparsos no limite inferior (a partir de 2018), principalmente após o marco da pandemia (início de 2020).

FIGURA 1

Perfil da série temporal nHora



Nota: Linhas pontilhadas e pontos vermelhos indicam o início dos períodos pré-pandêmico e pandêmico. A explicação de como foi montada a matriz horária de crimes encontra-se no texto.

Fonte: Elaborada pelos autores, com base em dados da Polícia Militar de Minas Gerais (PMMG).

A Figura 2 apresenta o resultado da análise espectral de frequências por MTSA aplicada sobre a série temporal nHora. Esse método permite identificar as frequências (ou os períodos) mais relevantes na série, por apresentarem picos mais proeminentes nessas frequências (ou períodos). Na Figura 2-A, pode-se ver o perfil do espectro de frequência para toda a nHora. Percebe-se picos relevantes indicando sazonalidade envolvendo os períodos de 12 e 24 horas. No período de 8 horas, o extremo inferior do intervalo de confiança deixa sua importância em dúvida, já que está muito perto das regiões de potências irrelevantes. Há um pequeno pico em 7 dias, mas a margem de erro inferior avança na região das potências sem destaques.

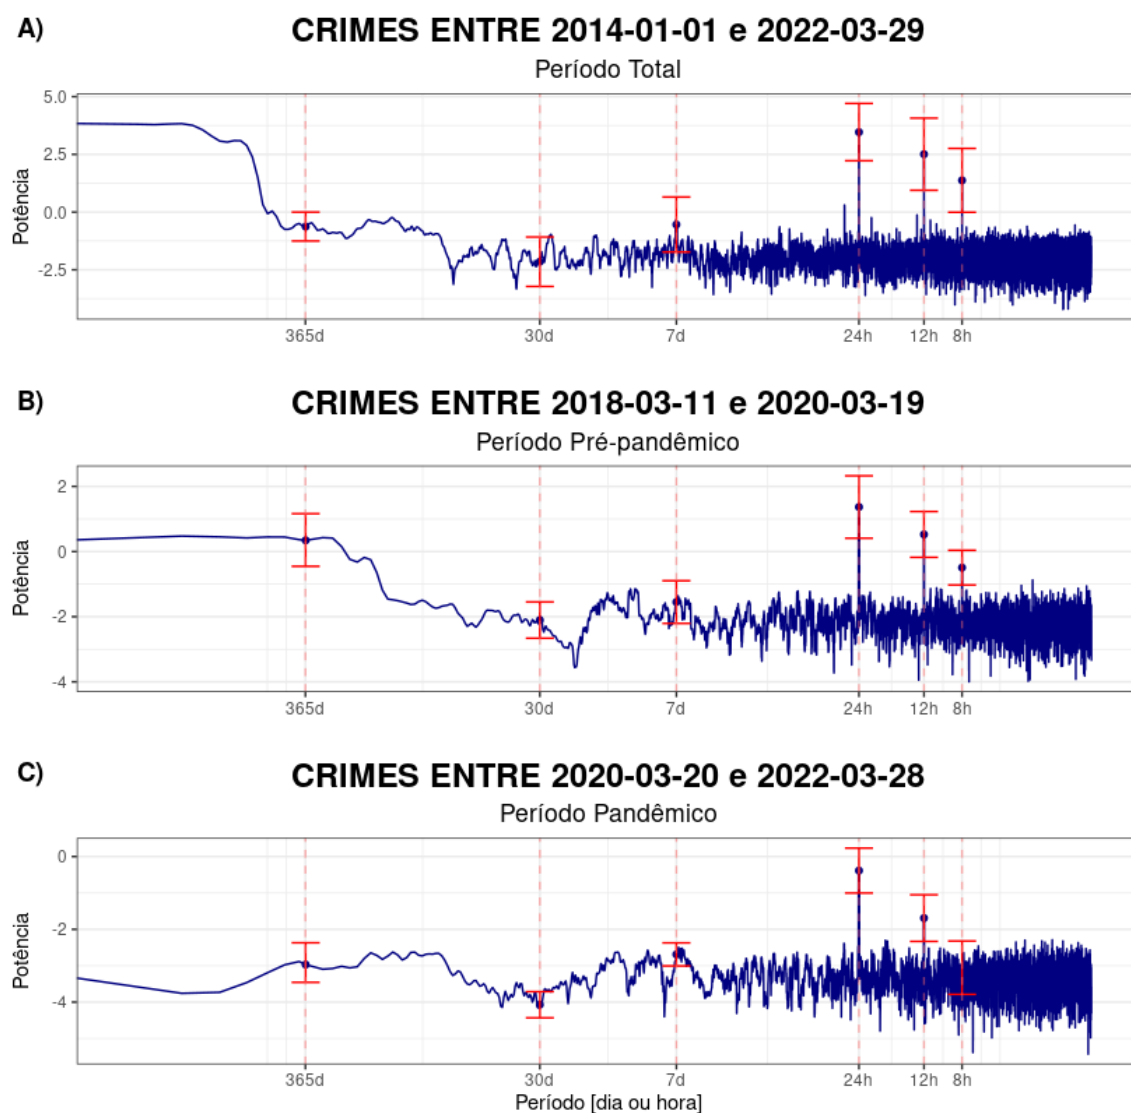
Nota-se ainda na Figura 2-A uma elevação ou um excesso de potência nas regiões de baixas frequências e períodos mais longos, após 365 dias. Essa elevação pode indicar um comportamento não estacionário nos dados (Rahim, 2014), em decorrência, principalmente, da presença de tendências (*trends*) ou variações nas médias dos valores em função do tempo. De fato, conforme observado na Figura 1-A, a distribuição de crimes no tempo segue um perfil não estacionário em relação às médias das ocorrências, com tendência clara de subida e queda, com modal entre 2017 e 2018, e posterior estabilização num patamar menor. Essa discussão será retomada mais adiante.

A Figura 2-B analisa o período pré-pandêmico, considerando o mesmo número de horas que o período pandêmico. Revela-se um padrão similar ao período geral, com um destaque menor para a oscilação de 7 dias. Nota-se também uma diminuição do excesso de potência nas baixas frequências, perto de 365 dias.

Já na Figura 2-C, na parte pandêmica da série temporal nHora, não se verifica esse excesso de potência nas baixas frequências. Tal comportamento sugere que as ocorrências de crimes podem ter adquirido um padrão estacionário ou pelo menos de tendência de médias de ocorrências estáveis durante a pandemia. Outro curioso padrão desse período é o enfraquecimento das frequências em 8 horas e 12 horas, principalmente a primeira, que passa a apresentar um intervalo de confiança indistinto das frequências sem destaques. A tênue força que existia antes na frequência de 7 dias, agora, se torna mais indistinta ainda. O único padrão periódico que parece não ter sido afetado pela pandemia é o de 24 horas.

FIGURA 2

Perfis da análise espectral de frequências da série temporal nHora



Nota: Ambos os eixos em escala logarítmica. O eixo X representa as frequências, mas os rótulos foram trocados por períodos, para melhor interpretação. Também para maior clareza visual, os intervalos de confiança no nível de 0,99 foram estimados apenas para as frequências/períodos em destaque.

Fonte: Elaborada pelos autores, com base em dados da Polícia Militar de Minas Gerais (PMMG).

Caracterização temporal de roubos de rua contrastando contextos pré-pandêmico e pandêmico


Renato Figueiredo Frade, Eric Fernandes de Mello Araujo, João Paulo Roquim Romanelli e Carlos Henrique da Silveira

Na Figura 3, há outra visualização que ajuda a interpretar os resultados dos periodogramas, com foco na análise comparativa entre o período pré-pandêmico (azul) e o pandêmico (vermelho). Nela, vê-se a série temporal nHora agrupada de 0 hora a 23 horas. Fica evidente um declínio geral no número de ocorrências em todos os horários, embora persistam indícios da sazonalidade diurno/noturno. Independente do perfil, as ocorrências crescem entre 15h da tarde e 1h da madrugada, com pico entre 21h e 22h. Fora desses horários, a taxa de crimes oscila entre 1/5 e 1/4 das máximas ocorrências. Provenza *et al.* (2015), analisando crimes de roubos e furtos na cidade do Rio de Janeiro, também encontram horários de pico entre 18h e 22h.

No período pré-pandêmico, notam-se pequenos picos diurnos, principalmente às 7h, às 10h e às 14h. No período pandêmico, o pico das 7h transforma-se num vale e o das 10h é atenuado. As maiores quedas ocorrem no horário das 2h (-81%) e das 7h (-87%). Pode-se hipotetizar que, com o confinamento e o trabalho remoto, houve menor deslocamento de pessoas para trabalhar nos períodos da madrugada e da manhã, afetando esses picos das 2h e das 7h.

FIGURA 3

Perfil agrupado de 0 a 23 horas da série temporal nHora



Nota: Os números entre as curvas indicam o percentual de queda no número de crimes conforme o horário. As linhas pontilhadas demarcam alguns horários comentados no texto.

Fonte: Elaborada pelos autores, com base em dados da Polícia Militar de Minas Gerais (PMMG).

Uma outra forma ainda de analisar os padrões temporais da série temporal nHora é através dos gráficos de autocorrelações, conforme mostrado na Figura 4. Foram utilizadas as funções de autocorrelação simples (ACF) e parcial (PACF). Conforme explicado na metodologia, ACFs computam correlações isoladas

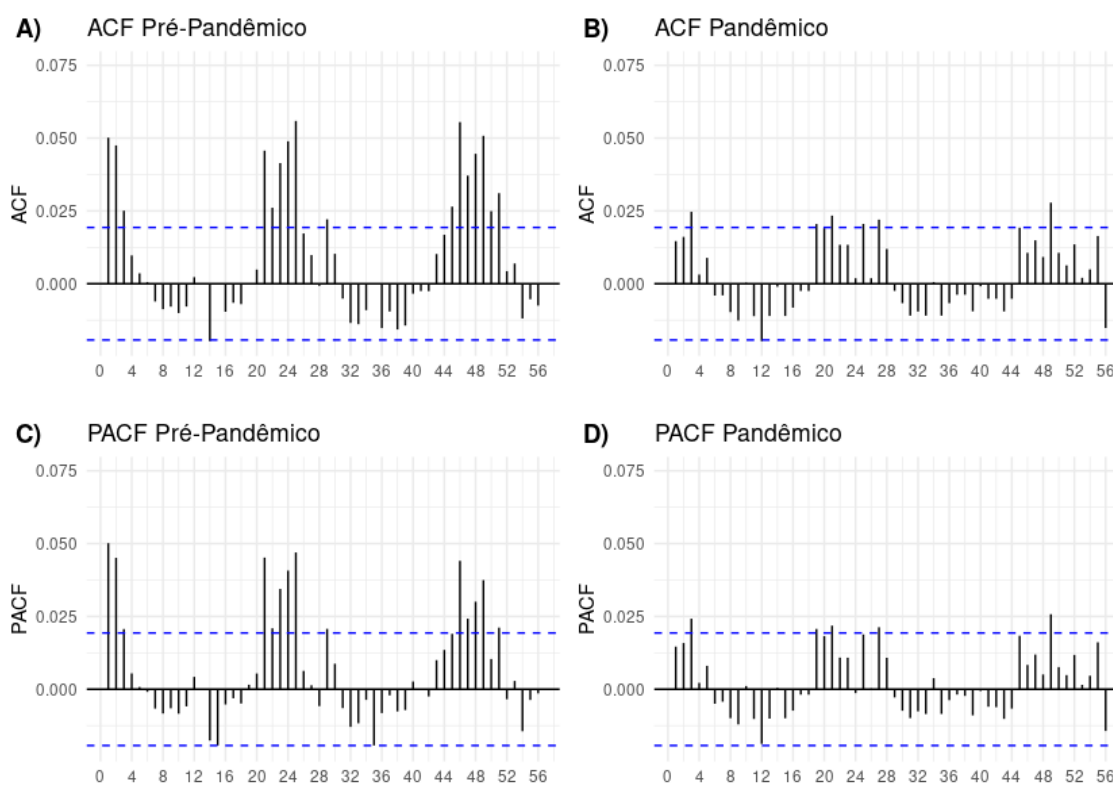
entre termos no tempo t e $t+h$, enquanto PACFs expurgam as influências dos termos intermediários entre eles e, logo, oferecem correlações mais puras.

Observam-se, para o período pré-pandêmico (Figuras 4-A e 4-C), indicativos tanto de tendências quanto de sazonalidades. As tendências ficaram evidenciadas pela presença de autocorrelações acima do intervalo de confiança a 0,99, para deslocamentos h pequenos, como de 1 a 3 ou no entorno dos picos. As sazonalidades, pela presença de ACF/PACF mais altos e positivos em períodos próximos de 24 horas (e seus múltiplos), e vales negativos em torno de 12 horas (e seus múltiplos). Tais resultados corroboram os vistos nas figuras anteriores. Mas não ficaram tão marcantes as autocorrelações com deslocamento de 8 horas, o que não é de todo incoerente com o gráfico do espectro de frequências para o período pré-pandêmico da Figura 2-B, cujo intervalo de confiança inferior mostrou-se próximo das potências irrelevantes.

Para o período pandêmico (Figuras 4-B e 4-D), os indicativos de tendências e de sazonalidades ficaram bem enfraquecidos. A maior parte das estimativas ficaram dentro do intervalo de confiança a 0,99, que delimita a região de oscilações aleatórias aceitáveis para ACF/PACF nulas. Trata-se de outro indicativo que reforça a ideia de algo mais próximo da estacionariedade nas ocorrências de crimes na pandemia; ou, pelo menos, que as tendências foram estabilizadas, diferentemente do período pré-pandêmico. A sazonalidade, ainda que enfraquecida, parece ter uma presença tênue no perfil das funções ACF e PACF, pelos picos e vales alternados que são vistos nessas figuras. Bom lembrar que, conforme visto na Tabela 1, a média de crimes que era de 1 crime a cada 9 horas, no período pré-pandêmico, caiu para 1 crime a cada 26 horas, no período pandêmico.

FIGURA 4

Perfil das autocorrelações da série temporal nHora



Nota: Linhas tracejadas em azul demarcam intervalo de confiança a 0,99.

Fonte: Elaborada pelos autores, com base em dados da Polícia Militar de Minas Gerais (PMMG).

Caracterização temporal de roubos de rua contrastando contextos pré-pandêmico e pandêmico

Renato Figueiredo Frade, Eric Fernandes de Mello Araujo, João Paulo Roquim Romanelli e Carlos Henrique da Silveira

Analisando no todo o conjunto de evidências reunidas até agora, uma conclusão possível é que a pandemia reduziu as ocorrências de crimes ao longo de todas as horas, tornando a série pandêmica próxima de um perfil estacionário, ainda que um viés de sazonalidade diurno/noturno não a tenha feito estritamente estacionária. Sugere que os crimes no período pandêmico passaram a ocorrer de forma muito mais aleatória ao longo das horas que no período pré-pandêmico. Tal aumento de aleatoriedade, no entanto, não desfez de todo a principal sazonalidade em torno de 24 horas que existia antes da pandemia. Isso fica claro na Figura 2, pois entre os picos agudos de maior potência, comparando períodos pré e pandêmico, apenas o de 24 horas mantém-se destacado das potências médias, considerando o intervalo de confiança no nível de 0,99.

Tais resultados podem ser interpretados à luz de duas teorias criminológicas importantes. A queda geral na frequência de crimes, do ponto de vista da Teoria da Atividade Rotineira (Cohen; Felson, 1979), pode ter sido consequência de uma ruptura dos três elementos que a fundamentam: um agressor motivado, um alvo apropriado e a ausência de um guardião eficaz. Desses três, é razoável pressupor que a pandemia tenha tido maior influência nos dois primeiros, já que a diminuição e a irregularidade da presença de vítimas em potenciais cenários de crimes podem ter desmotivado a ação criminosa. Na Teoria dos Padrões de Crime (Brantingham; Brantingham, 2013), que tem foco no papel do espaço e das rotas rotineiras no comportamento criminoso, com menos deslocamentos e a retração de “áreas-alvo”, como centros comerciais, transportes públicos e espaços de convivência, em função da pandemia, os criminosos podem ter tido menos oportunidades para identificar locais propícios ao crime de rua.

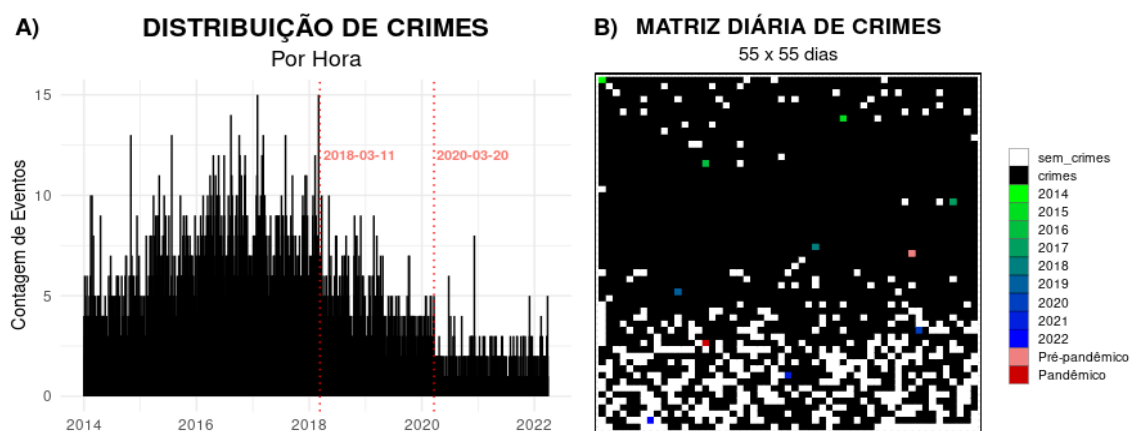
SÉRIE TEMPORAL DE CRIMES POR DIA

Aqui, avança-se da análise de crimes por hora para a escala seguinte: por dia, na série temporal nDia. A Figura 5 faz uma panorâmica dessa nova escala diária. Na Figura 5-A ficam mais claras as tendências já vistas na nHora, evidenciando um perfil de crimes que aumenta desde 2014, passa por um platô em 2017, e começa a decair em 2018, estabilizando-se a partir de 2020.

Na Figura 5-B tem-se a mesma formatação conforme descrito na matriz da Figura 1-B, mas consolidada em crimes por dia, com acréscimo de marcações do início de todos os anos (de 2014 a 2022), coloridos conforme legenda. Como esperado, há uma diminuição da esparsidade, pela menor quantidade de pontos brancos (dias sem registro de crimes). Dos 3.010 dias de toda a série, em apenas 435 não se registraram crimes, o equivalente a 14,5% dos dias.

FIGURA 5

Perfil da série temporal nDia



Nota: As linhas pontilhadas em A) indicam o início dos períodos pré-pandêmico e pandêmico. Explicação de como foi montada a matriz diária de crimes encontra-se no texto.

Fonte: Elaborada pelos autores, com base em dados da Polícia Militar de Minas Gerais (PMMG).

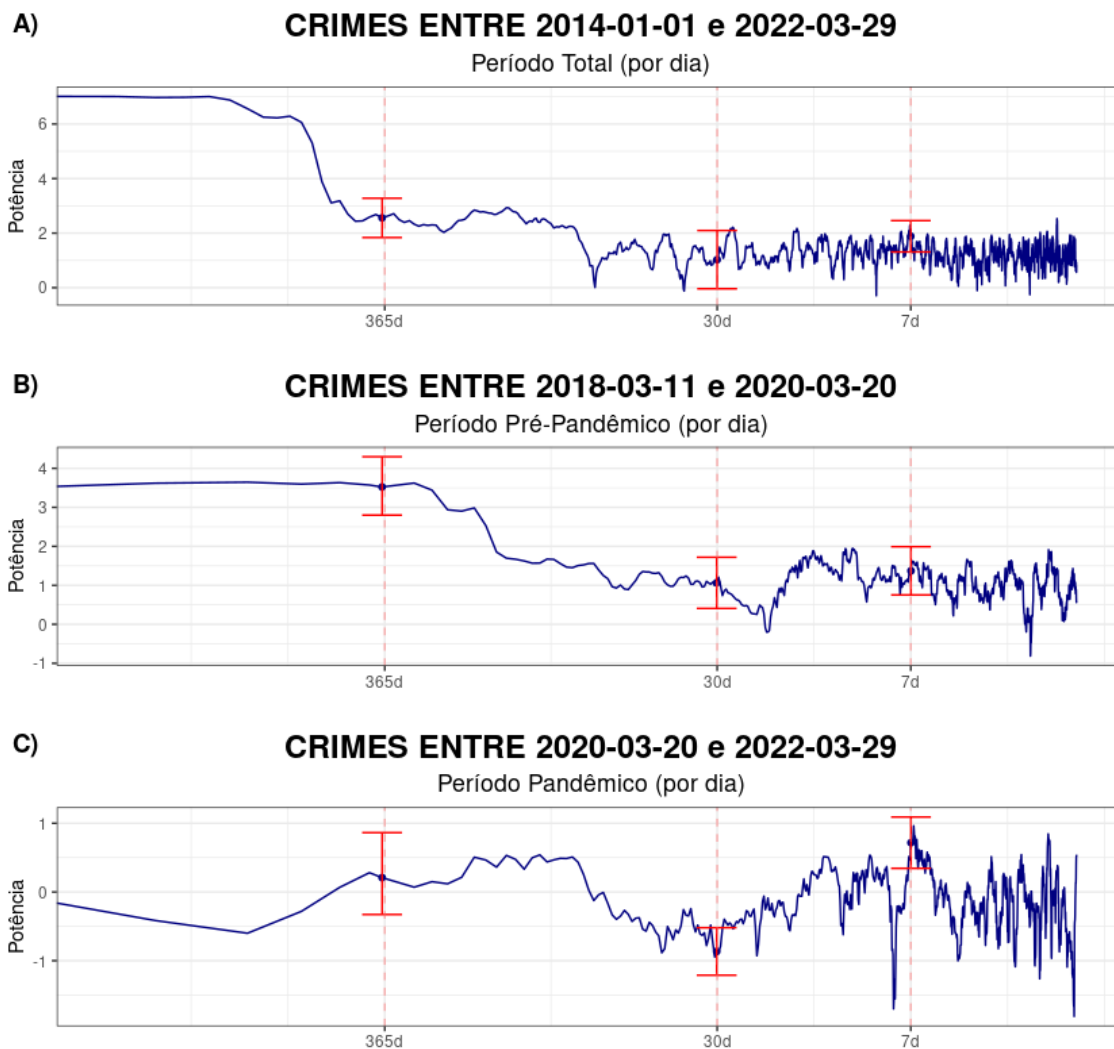
O aumento das ocorrências em 2016 e 2017 fica evidente pela quase ausência desses pontos brancos. No ano de 2017, inclusive, não houve um dia sequer sem ocorrência de pelo menos um crime. Mas, a partir de 2018, começa a aparecer maior presença de pontos brancos, intensificados de 2020 em diante. Em relação aos 740 dias do período pré-pandêmico, em 96 deles não houve crimes registrados, o que equivale a 13% dos dias. No período pandêmico, com mesmo número de dias, em 300 deles não houve crimes registrados, ou seja, em 40,5% dos dias. A esparsidade do período pandêmico foi mais de 3 vezes maior que no período pré-pandêmico. No período pandêmico, há sequências de 5 e até 6 dias consecutivos sem crimes, algo inédito em toda a série de dados.

Na Figura 6, observa-se o espectro de frequências da série temporal nDia. Seja na série como um todo ou nos períodos pré-pandêmico ou pandêmico, o espectro não indica presença de sazonalidade significativa por esse método, pois não há picos relevantes em nenhuma faixa de frequência/período.

Detecta-se apenas a elevação típica das potências em frequências mais baixas (períodos mais longos) nas Figuras 6-A e 6-B, algo sugestivo da presença de tendências na série de dados. Já o período pandêmico, na Figura 6-C, não acusa tendências, mas a possibilidade de uma série próxima da estacionalidade, como visto também na Figura 2-C.

FIGURA 6

Perfis da análise espectral de frequências da série temporal nDia



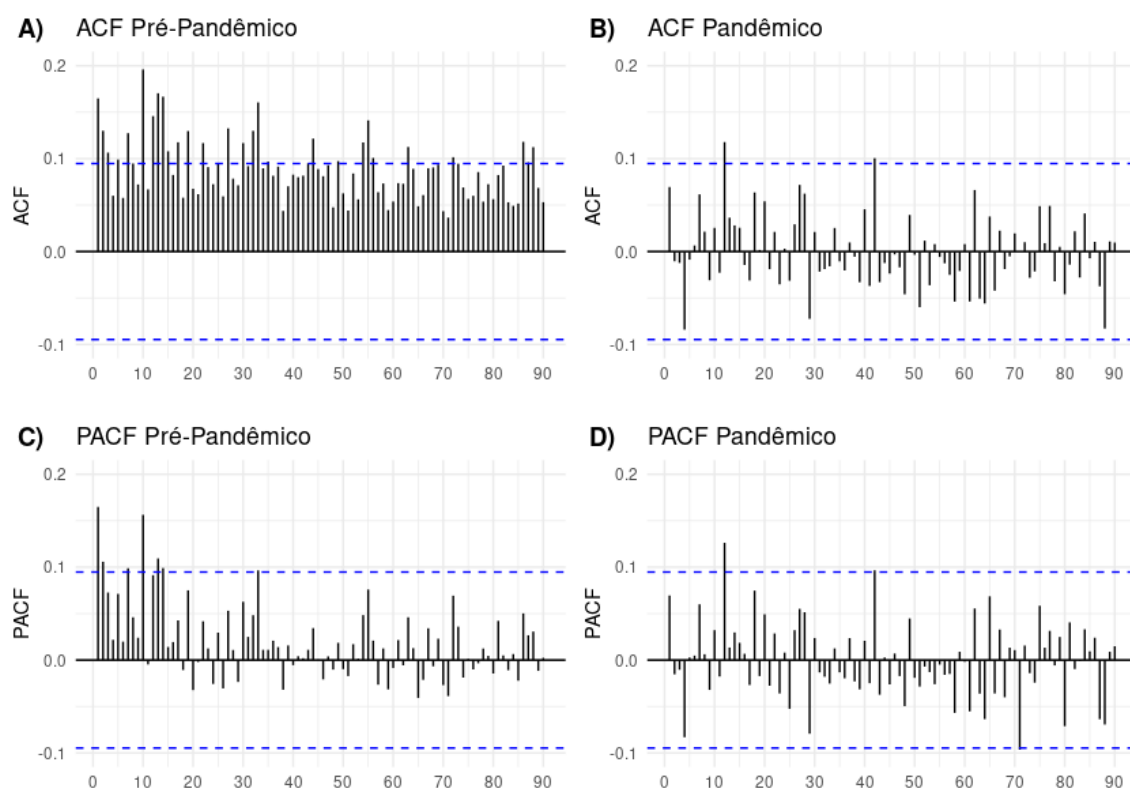
Nota: Ambos os eixos em escala logarítmica. O eixo X representa as frequências, mas os rótulos foram trocados por períodos, para melhor interpretação. Também para maior clareza, os intervalos de confiança no nível de 0,99 foram estimados apenas para as frequências/períodos em destaque.

Fonte: Elaborada pelos autores, com base em dados da Polícia Militar de Minas Gerais (PMMG).

Os gráficos da Figura 7 de autocorrelações ACF/PACF da série temporal nDia parecem confirmar as observações espectrais anteriores, pois não há evidências de sazonalidades diárias, seja no período pré-pandêmico ou no pandêmico. No que diz respeito às tendências, elas parecem presentes no período pré-pandêmico, pelo decaimento das correlações ao longo dos deslocamentos temporais, principalmente na ACF. Reforça essa interpretação o fato de não se constatar correlações negativas na ACF. Mas, no período pandêmico, o indício de estacionariedade na nDia é muito mais forte que na nHora, dado que pelo menos 99% das correlações estão no intervalo de confiança, sem indícios de tendências ou sazonalidades. Pode-se inferir que, na granularidade de dias, no período pandêmico, o comportamento dos crimes mostrou-se tipicamente aleatório e imprevisível, no sentido de não haver tendências ou sazonalidades que pudessem ser exploradas numa eventual previsão.

FIGURA 7

Perfil das autocorrelações da série temporal nDia



Nota: Linhas tracejadas em azul demarcam intervalo de confiança a 0,99.


Fonte: Elaborada pelos autores, com base em dados da Polícia Militar de Minas Gerais (PMMG).

Na Figura 8, pode-se acompanhar o perfil das ocorrências consolidado por dia da semana, entre os períodos: total (preto), pré-pandêmico (azul) e pandêmico (vermelho). Um primeiro ponto a ser considerado é que os perfis são semelhantes, com ligeiras elevações nas segundas e quartas, e pequeno declínio nos finais de semana. No período Total, os intervalos de confiança parecem todos sobrepostos, exceção (talvez) entre o pequeno vale no domingo e os também pequenos picos nas segundas e quartas. Nos períodos pré-pandêmico e pandêmico, a sobreposição é geral, sugerindo uma indiferença entre as médias de crimes por dia da semana.

Pode-se concluir, com relação à série temporal nDia, que as ocorrências de crimes por dia não apresentaram sazonalidades importantes. Nessa escala, não foi possível caracterizar dias preferenciais para um evento criminoso acontecer, nem mesmo considerando os dias da semana. O senso comum poderia conceber uma maior probabilidade de crimes nos fins de semana, especialmente nas sextas ou sábados, ou nas segundas, mesmo considerando o recorte dos dados em cidades de tamanho médio e do interior. Este trabalho não encontrou evidência estatística que corroborasse esse senso comum. Algo similar é encontrado por Provenza *et al.* (2015) para roubos e furtos no município do Rio de Janeiro. Andresen e Malleson (2015) também não detectaram padrões consistentes em relação aos dias da semana para esse tipo de crime (*street robbery*) na cidade de Vancouver, no Canadá. Em relação ao período pandêmico, na escala de dias, ganhou mais evidência ainda o seu padrão estacionário. A existência desse padrão sugere um comportamento de ocorrências de crimes muito próximo do aleatório ao longo dos dias do ano.

FIGURA 8

Perfil por dia da semana da série temporal nDia, conforme a média semanal de crimes



Nota: Barras indicam o intervalo de confiança das médias a 0,99.

Fonte: Elaborada pelos autores, com base em dados da Polícia Militar de Minas Gerais (PMMG).

SÉRIE TEMPORAL DE CRIMES A CADA DEZ DIAS

Outra granularidade temporal que merece ser explorada é a condensada de 10 em 10 dias, que segmenta os meses em três partes, na série temporal nDez. A intenção é ver se há algum padrão que diferencie os 10 primeiros dias de cada mês, os dias em torno da metade do mês (dia 15) e os últimos 10 dias do mês. Quer-se verificar se há viés de ocorrência de crimes mais no início do que no fim do mês, dada a condição provável da população, no geral, estar com mais dinheiro no princípio do mês (em função dos recebimentos de salário) do que tardiamente no mês. A escolha dessa periodicidade deveu-se também ao fato de a PMMG ter feito esse recorte nos dados fornecidos.

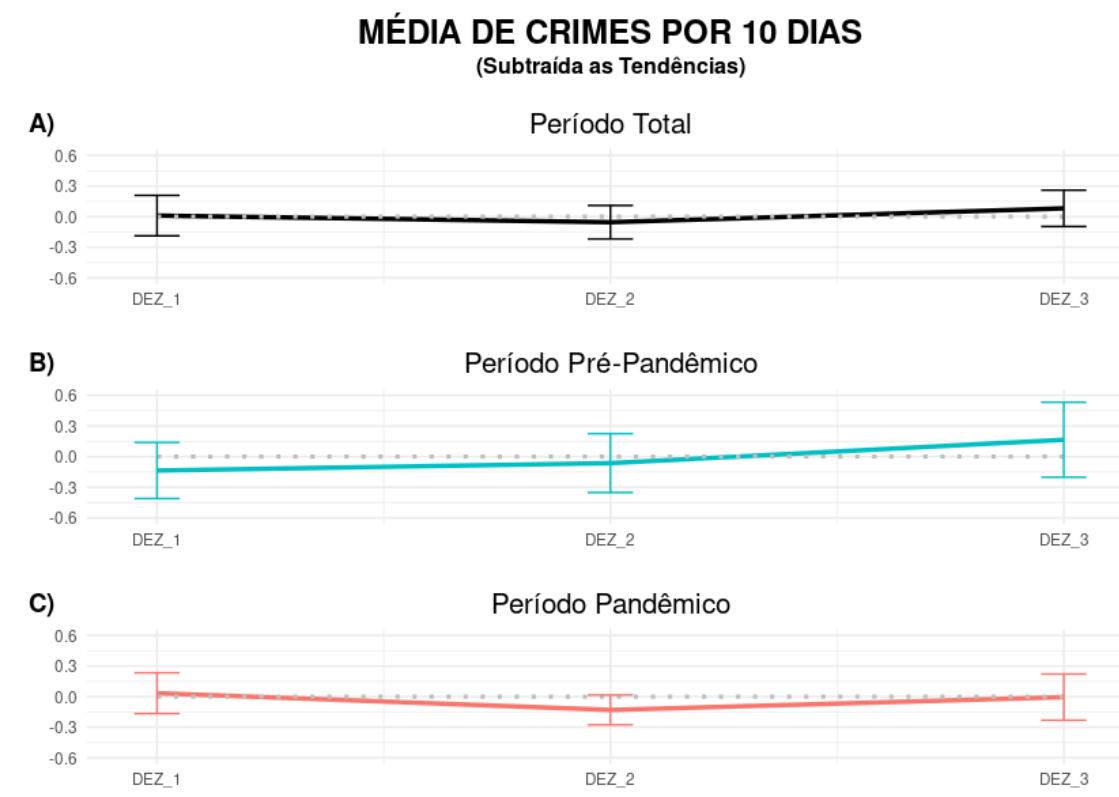
Um detalhe importante a ser considerado para esta análise é que a quantidade de dias varia, dependendo do mês, entre 28, 29 (nos anos bissextos), 30 ou 31 dias. Isso fez com que os últimos 10 dias de cada mês pudessem ter variações quantitativas no número de dias (obviamente, também de crimes), enviesando a quantidade de crimes na última dezena. Para corrigir essa anomalia, trabalhou-se com a média de crimes ao longo de cada dezena.

Esse procedimento também permitiu transformar os dados que eram inteiros (quantidade de crimes) em valores mais contínuos (média de crimes por dezena). Como não houve 10 dias seguidos sem crimes, a série nDez não é mais esparsa. Essas condições preencheram requisitos para um uso mais confiável de técnicas clássicas em séries temporais (Davis *et al.*, 2021), tais como a decomposição STL (Cleveland *et al.*, 1990). Em especial, o uso dessa decomposição permite subtrair as tendências do sinal original.

Mais uma vez, não foram encontrados sinais de sazonalidade dominantes, seja na análise espectral de frequências ou nos gráficos de autocorrelações (dados não mostrados). Isso também pode ser visto na Figura 9, que revela o perfil consolidado das médias de crimes ao longo das três dezenas, para os períodos total, pré-pandêmico e pandêmico. Independente do período, a sobreposição dos intervalos de confiança indica não haver diferenças significativas entre as médias por dezena. O senso comum falha uma vez mais pois, para o tipo de crime analisado aqui, não importa se é início, meio ou fim de mês.

FIGURA 9

Perfil da série temporal nDez, consolidada por média de crimes a cada 10 dias do mês



Nota: Barras indicam o intervalo de confiança das médias a 0,99.

Fonte: Elaborada pelos autores, com base em dados da Polícia Militar de Minas Gerais (PMMG).

SÉRIE TEMPORAL DE CRIMES A CADA MÊS

A última granularidade temporal analisada foi a de crimes por mês, na série temporal nMês. Como também feito no caso das dezenas, trabalhou-se aqui com a média de crimes por mês, dado que há variação na quantidade de dias em cada mês. A simples contagem de crimes por mês introduziria um viés, uma vez que meses com mais dias tenderiam a acumular mais crimes. Essa transformação de contagens de crimes por média de crimes permite também trabalhar com dados numa forma próxima do contínuo, em vez de discreto, habilitando o uso mais confiável da decomposição STL.

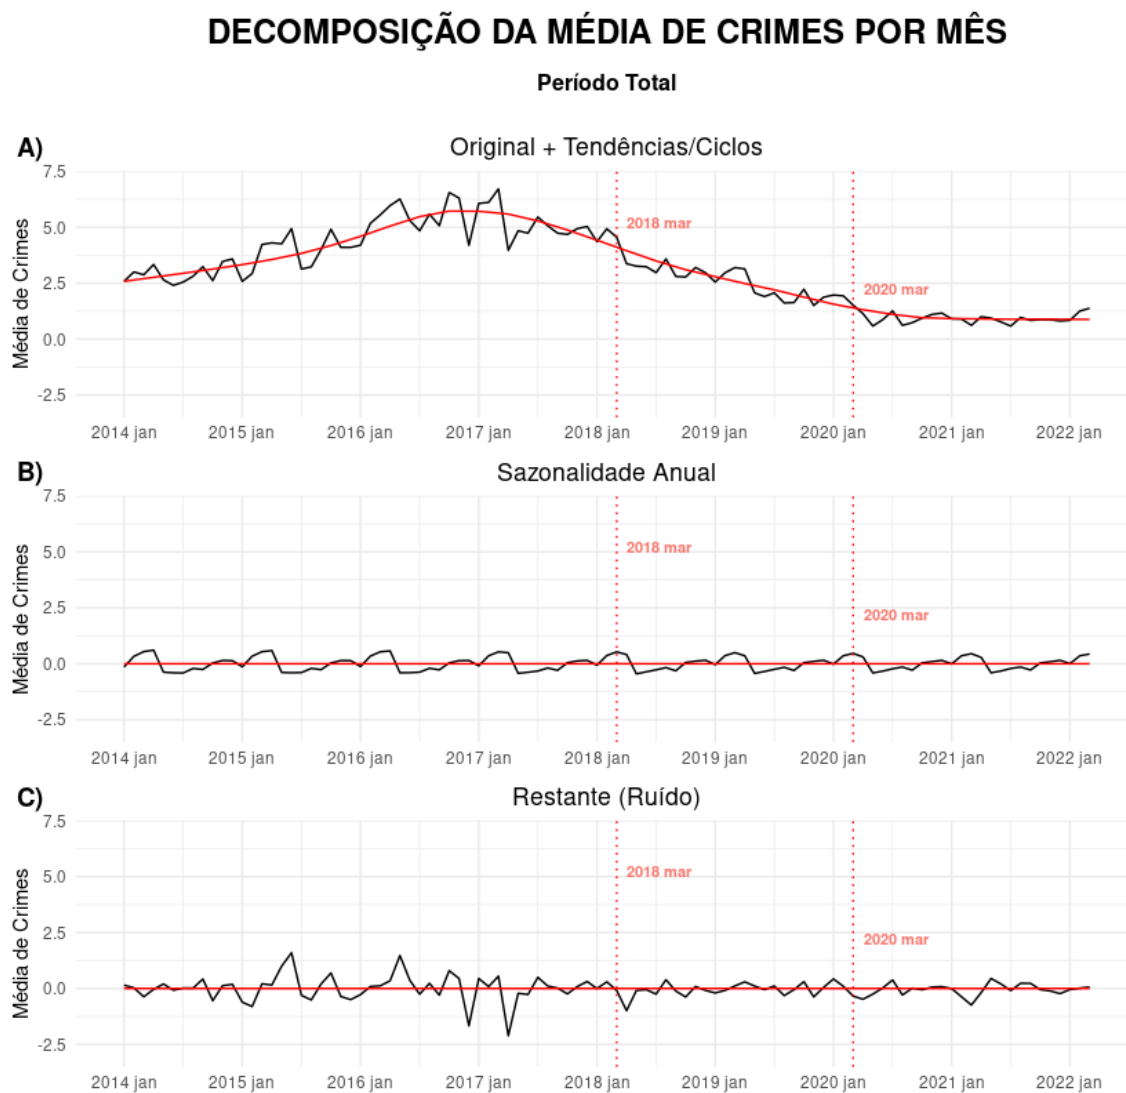
A Figura 10 mostra o resultado da decomposição STL da série temporal nMês. Na Figura 11-A, veem-se, de maneira sobreposta: o sinal original da média de crimes por mês (em preto) e a componente Tendência/Ciclo em vermelho. A decomposição da nMês encontrou um sinal de sazonalidade anual, com um modal entre março e abril, conforme visto na Figura 10-B. O restante do sinal, tido como um ruído, está na Figura 10-C.

Foi calculado o índice de força (*strength*) das componentes Tendência/Ciclo (FT) e Sazonalidade Anual (FS), conforme as equações descritas na metodologia. Lembrando que, nesses índices, quanto mais próximo de 1, maior a força ou importância da componente; e quanto mais próximo de 0 (zero), o contrário.

A decomposição da série temporal nMês encontrou $FT = 0,92$ e $FS = 0,10$, indicando que a componente Tendência/Ciclo é considerada marcante, mas o sinal da Sazonalidade Anual, fraco ou de pouca importância. De fato, tanto a análise espectral de frequências quanto a análise das autocorrelações corroboraram com o índice FS baixo, pois não revelaram uma periodicidade preponderante no sinal da nMês (dados não mostrados).

FIGURA 10

Decomposição STL da série temporal nMês



Fonte: Elaborada pelos autores, com base em dados da Polícia Militar de Minas Gerais (PMMG).

Por fim, a Figura 11 oferece uma visão consolidada por mês das médias de crimes, subtraídas as Tendências/Ciclos. Na Figura 11-A, para o período Total, vê-se que os intervalos de confiança (a 0,99) sobrepoem-se na maioria dos meses, com exceção para o mês de março, cujo limite inferior da barra de erro chega próximo de zero. O mês de abril foi o que apresentou maior variação da média mensal apurada. Nas Figuras 11-B e 11-C, têm-se os perfis para os períodos pré-pandêmico e pandêmico, respectivamente. Não foi possível estimar o intervalo de confiança, pois cada mês contou apenas com dois pontos amostrais, restando apenas uma análise mais qualitativa nesses períodos. Percebe-se que o período pré-pandêmico apresentou um perfil mais próximo do Total, enquanto no período pandêmico os desvios foram mais homogêneos e próximos de zero.

Logo, pode-se concluir que, na escala de meses, os dados não foram suficientes para atestar, com segurança estatística, distinção dos meses para com a média mensal de crimes, seja no período total, pré-pandêmico ou pandêmico. Qualquer que seja o mês, a média de crimes é a mesma, não havendo um mês

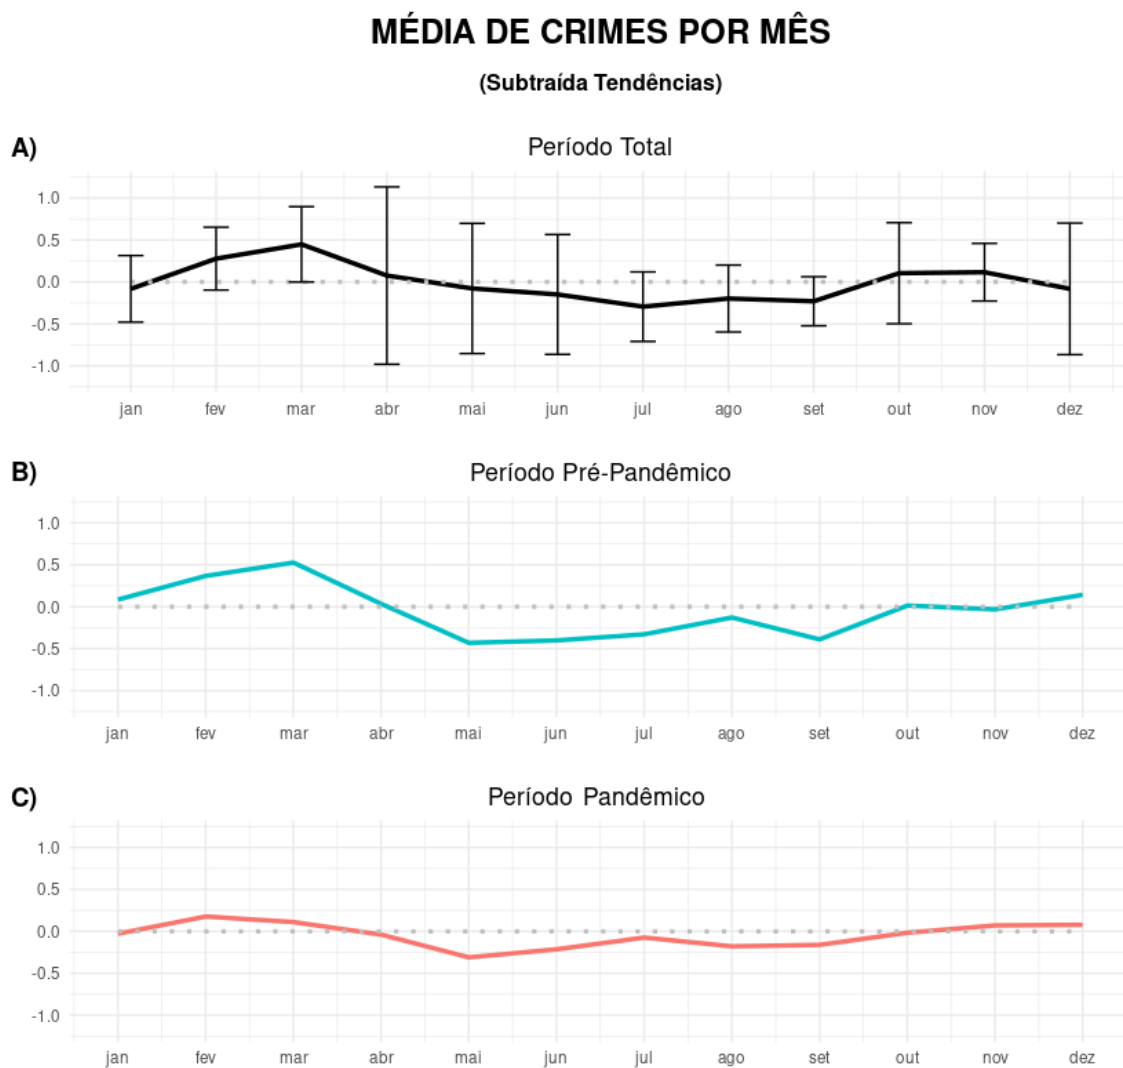
Caracterização temporal de roubos de rua contrastando contextos pré-pandêmico e pandêmico

Renato Figueiredo Frade, Eric Fernandes de Mello Araujo, João Paulo Roquim Romanelli e Carlos Henrique da Silveira

preferencial a qualquer outro. O mês de março apresenta um viés de distinção mas, no conjunto, essa distinção não teve suporte estatístico convincente.

FIGURA 11

Perfil da série temporal nMês, consolidada por média de crimes em cada mês



Nota: As barras indicam o intervalo de confiança das médias a 0,99. Não foram mostradas barras de erro para os perfis pré-pandêmico e pandêmico, dado que a amostragem compreendeu apenas duas apurações para cada mês. Logo, para esses perfis, só restou uma análise qualitativa.

Fonte: Elaborada pelos autores, com base em dados da Polícia Militar de Minas Gerais (PMMG).

CONSIDERAÇÕES FINAIS

O principal desafio deste trabalho foi empreender uma minuciosa caracterização temporal sobre as ocorrências de crimes de roubo de rua, provenientes de registros de BOs da PMMG, em algumas cidades de porte médio de Minas Gerais, entre janeiro de 2014 e março de 2022. Tal intervalo de tempo abrangeu períodos não pandêmicos e pandêmicos, sendo possível submeter tais períodos a um escrutínio temporal

comparativo, em diferentes escalas. Os métodos utilizados na mineração de padrões temporais levaram em conta a esparsidade e a ocorrência discreta dos eventos de crimes no tempo.

Na escala de horas, a taxa de crimes que apresentava uma média de 1 crime a cada 9 horas no período pré-pandêmico caiu para a média de 1 crime a cada 26 horas no período pandêmico, queda geral de aproximadamente 64%. As maiores quedas foram registradas nos horários das 2h da madrugada (-81%) e 7h da manhã (-87%). Foi identificada uma sazonalidade marcante com período de 24 horas, com os picos máximos de ocorrências noturnas sendo entre quatro e cinco vezes maiores que as diurnas. Esses picos tenderam a ocorrer entre 21h e 22h da noite. Embora mais enfraquecida e com maior ganho de aleatoriedade, essa sazonalidade entre turnos diurnos e noturnos manteve-se no período pandêmico.

Tais resultados são coerentes com a Teoria da Atividade Rotineira (Cohen; Felson, 1979) e a Teoria dos Padrões de Crimes (Brantingham; Brantingham, 2013). A ruptura na regularidade de comportamento ou no padrão rotineiro dos alvos pode explicar a maior aleatoriedade das ocorrências de crimes durante a pandemia, uma vez que o isolamento social pode ter tornado menos previsíveis os momentos e os locais em que ocorreram as interações entre criminosos e vítimas. Mas tal aleatoriedade não foi suficiente para romper a sazonalidade básica entre períodos diurno e noturno, uma tendência temporal de mais alta inércia que não se arrefeceu completamente, mesmo na pandemia.

Nas demais escalas, de dias, em dezenas de dias e por mês, não foram detectadas sazonalidades significativas, independente do período pré-pandêmico ou pandêmico, contrariando alguns preceitos do senso comum. Por exemplo, é provável que esse senso apostasse em ocorrências diferenciadas entre finais de semana e dias comuns da semana; ou considerasse maior ocorrência nos dias iniciais do mês, dado o recebimento de salários; ou nos últimos meses do ano, em função do 13º salário e das movimentações festivas típicas do fim do ano. Porém, diferentes métodos de aferição de sazonalidades convergiram para a mesma conclusão: de que a taxa média de roubos de rua mostrou-se indiferente aos dias da semana, se início ou fim de mês, ou entre os meses do ano. Implica que a probabilidade de ocorrências desse tipo de crime foi estatisticamente a mesma em todas essas escalas temporais.

Como apregoa a Teoria da Atividade Rotineira (Cohen; Felson, 1979), crimes como roubos de rua dependem de interações imediatas entre criminoso, vítima e presença das forças e dos aparatos de segurança. Em outras granularidades que não das horas do dia, parece que a natureza oportunista do roubo de rua destaca sua dependência de interações momentâneas e espúrias, em vez de padrões temporais fixos como dias da semana ou meses do ano. A adaptabilidade dos agressores e a dependência do crime em oportunidades imediatas tornam-no menos previsível nessas escalas temporais. Isso exige que os esforços de prevenção de crimes se concentrem mais nas dinâmicas em tempo real do que em padrões de médio ou longo prazos. Mesmo assim, não deixa de ser curiosa a evidência, nas cidades analisadas, da existência apenas de padrões sazonais na escala de horas, e não nas demais, como em dias da semana, partes dos meses ou meses do ano.

Do ponto de vista das tendências gerais, no intervalo de tempo analisado, constatou-se que a partir de 2014 houve um aumento das ocorrências, com modal na transição entre 2016 e 2017, e posterior queda gradativa até a estabilização no período pandêmico, entre 2020 e 2022. Em todas as escalas temporais consideradas, a característica mais marcante da pandemia foi um padrão mais estacionário de ocorrências de crimes. Conclui-se que tais eventos ganharam maior aleatoriedade na pandemia do que antes dela, não sendo possível discernir padrões de tendências ou sazonalidades (exceção as oscilações diurno/no-

Caracterização temporal de roubos de rua contrastando contextos pré-pandêmico e pandêmico

Renato Figueiredo Frade, Eric Fernandes de Mello Araujo, João Paulo Roquim Romanelli e Carlos Henrique da Silveira

turno na escala de horas). Logo, se por um lado, durante o período pandêmico, houve um recuo para um patamar quase três vezes menor no número de ocorrências, por outro lado, os crimes de roubo de rua tornaram-se mais imprevisíveis.

É importante salientar algumas limitações deste trabalho. A primeira delas diz respeito à proveniência dos dados, englobando um conjunto estrito de cidades do interior de Minas Gerais. Embora sejam cidades com porte e características similares, suas escolhas não se deram por uma amostragem aleatória. Tal limitação, porém, não invalida as conclusões aqui destacadas, apenas deve-se ter cautela em eventuais generalizações para além desse escopo. Outra limitação é que houve foco apenas nos crimes de roubos de rua, tipificados no art. 157 do Código Penal. Foi um foco estratégico, dada a presunção da sua correlação com a mobilidade da população, por sua vez criticamente afetada pela pandemia. A expansão da análise para outros tipos de crimes ficou para estudos futuros.

A pandemia de covid-19 teve impactos significativos na dinâmica da criminalidade de rua no conjunto das cidades analisadas, com resultados que podem ser reflexos das mudanças drásticas nas vidas cotidianas dos cidadãos durante aquele período. Embora este artigo não tenha cruzado dados de criminalidade de rua com as taxas de circulação das pessoas, outros artigos evidenciaram que as medidas de isolamento social e as restrições de mobilidade desempenharam um papel importante na diminuição da atividade criminosa (Monteiro; Carvalho; Gomes, 2021; Oliveira, 2022). As mudanças nas rotinas, com menos pessoas circulando nas ruas e mais tempo gasto em casa, podem ter dissuadido a oportunidade de cometer crimes ou simplesmente limitado a exposição a situações criminosas; algo coerente com a Teoria da Atividade Rotineira (Cohen; Felson, 1979) e a Teoria dos Padrões de Crime (Brantingham; Brantingham, 2013).

Em última análise, este artigo indica que compreender essas mudanças é essencial para orientar políticas públicas e estratégias de segurança, não apenas para responder a crises sanitárias globais, mas também para melhorar a segurança pública de forma mais ampla. Mais especificamente, sugere considerar, por exemplo, que as ações estratégicas de segurança pública para crimes de roubos de rua (nas cidades analisadas) deva se concentrar mais na escala das horas do dia (dada a resistente sazonalidade diurno/noturno), em detrimento de outras escalas temporais, como dias da semana, início ou fim de mês ou mesmo meses do ano. O uso de dados em tempo real nas análises preditivas pode otimizar a alocação policial nas situações em que a aleatoriedade dos eventos possa ter um peso maior. A análise desses dados continuará a fornecer *insights* valiosos para uma tomada mais estratégica de decisões baseadas em evidências.

REFERÊNCIAS

ALVES, Janael da Silva. A influência do isolamento social durante a pandemia da covid-19 sobre as taxas de crimes violentos em 20 municípios do sul de Minas Gerais. **Boletim Alfenense de Geografia**, Alfenas, v. 2, n. 3, p. 98-121, 2022. DOI: <https://doi.org/10.29327/243949.2.3-6>.

ALVES, Luís; RIBEIRO, Haroldo; RODRIGUES, Francisco. Crime prediction through urban metrics and statistical learning. **Physica A: Statistical Mechanics and its Applications**, v. 505, p. 435-443, 2018. DOI: <https://doi.org/10.1016/j.physa.2018.03.084>.

ANDRESEN, Martin; MALLESON, Nick. Intra-week spatial-temporal patterns of crime. **Crime Science**, v. 4, n. 12, 2015. DOI: <https://doi.org/10.1186/s40163-015-0024-7>.

ARAÚJO, Eric; GERRITSEN, Charlotte. Creating a temporal pattern for street robberies using ABM and data from a small city in South East Brazil. *In*: GERRITSEN, Charlotte; ELFFERS, Henk (Eds.). **Agent-Based Modelling for Criminological Theory Testing and Development**. 1. ed. London: Routledge, 2020, p. 146-166.

ATALAN, Abdulkadir. Is the lockdown important to prevent the COVID-19 pandemic? Effects on psychology, environment and economy-perspective. **Annals of Medicine and Surgery**, v. 56, p. 38-42, 2020. DOI: <https://doi.org/10.1016/j.amsu.2020.06.010>.

BRANTINGHAM, Paul; BRANTINGHAM, Patricia. Crime pattern theory. *In*: WORTLEY, Richard; MAZEROLLE, Lorraine (Eds.). **Environmental Criminology and Crime Analysis**. 1. ed. London: Willan, 2013, p. 100-116.

BRASIL. Poder Executivo. Decreto-Lei Nº 2.848, de 7 de dezembro de 1940. Código Penal. Brasília: **Diário Oficial da União**, Seção 1, p. 23911, 31 dez. 1940.

CASTRO, Celia; HOLANDA, Fabiane; CARVALHO, Joadson; BARBOSA, José; GOMES, Anna. Homicídios no Rio Grande do Norte e sua relação com a pandemia do COVID-19. **EmpiricaBR**, Natal, v. 1, n. 1, p. 1-19, 2021. DOI: <https://doi.org/10.15628/empiricabr.2021.13264>.

CLEVELAND, Robert; CLEVELAND, William; MCRAE, Jean; TERPENNING, Irma. STL: a seasonal-trend decomposition procedure based on loess. **Journal of Official Statistics**, v. 6, n. 1, p. 3-73, 1990.

COHEN, Lawrence; FELSON, Marcus. Social change and crime rate trends: a routine activity approach. **American Sociological Review**, v. 44, n. 4, p. 588-608, 1979. DOI: <https://doi.org/10.2307/2094589>.

DAVIS, Richard; FOKIANOS, Konstantinos; HOLAN, Scott; HARRY, Joe; LIVSEY, James; LUND, Robert; PIPIRAS, Vlas; RAVISHANKER, Nalini. Count time series: a methodological review. **Journal of the American Statistical Association**, v. 116, n. 535, p. 1533-1547, 2021. DOI: <https://doi.org/10.1080/01621459.2021.1904957>.

EFRON, Bradley. **The jackknife, the bootstrap and other resampling plans**. Technical Report n. 63. California: Stanford University, 1980. Disponível em: https://stacks.stanford.edu/file/druid:mm176gm7964/mm176gm7964_EFS-NSF-163.pdf. Acesso em: 5 out. 2023.

GREEN, James. Too many zeros and/or highly skewed? A tutorial on modelling health behaviour as count data with Poisson and negative binomial regression. **Health Psychology and Behavioral Medicine**, v. 9, n. 1, p. 436-455, 2021. DOI: <https://doi.org/10.1080/21642850.2021.1920416>.

GROFF, Elizabeth. Simulation for theory testing and experimentation: an example using routine activity theory and street robbery. **Journal of Quantitative Criminology**, v. 23, n. 2, p. 75-103, 2007. DOI: <https://doi.org/10.1007/s10940-006-9021-z>.

HYNDMAN, Rob; ATHANASOPOULOS, George. **Forecasting: principles and practice**. 3. ed. Melbourne, Australia: OTexts, 2021. E-book. Disponível em: <https://otexts.com/fpp3>. Acesso em: 5 out. 2023.

HOU, Miaomiao; ZHAOLONG, Zeng; XIAOFENG, Hu; JINMING Hu. Investigating the impact of the COVID-19 pandemic on crime incidents number in different cities. **Journal of Safety Science and Resilience**, v. 3, n. 4, p. 340-352, 2022. DOI: <https://doi.org/10.1016/j.jnlssr.2021.10.008>.

ITABIRA (MG). Decreto Nº 3.178, de 19 de março de 2020. Determina a suspensão temporária dos Alvarás de Localização e Funcionamento e autorizações emitidos para realização de atividades com potencial de aglomeração de pessoas para enfrentamento da Situação de Emergência Pública causada pelo agente Coronavírus - COVID-19. Itabira/MG: **Diário Oficial de Itabira**, n. 8.361, 19 mar. 2020. Disponível em: https://www.itabira.mg.gov.br/arquivo/legislacao/decreto_3178_2020. Acesso em: 7 jul. 2023.

Caracterização temporal de roubos de rua contrastando contextos pré-pandêmico e pandêmico

Renato Figueiredo Frade, Eric Fernandes de Mello Araujo, João Paulo Roquim Romanelli e Carlos Henrique da Silveira

LEAL, Manoel Flavio; GOMES JUNIOR, Luiz. Impacto da Pandemia da COVID-19 nos Padrões de Crimes no Município de Curitiba. In: **Anais da XVII ERBD – Escola Regional de Banco de Dados**. Lages: IFSC, 2022, p. 101-108. DOI: <https://doi.org/10.5753/erbd.2022.223619>.

LOBO, Andréa de Paula; SANTOS, Augusto César Cardoso dos; ROCHAB, Marli Souza; PINHEIRO, Rejane Sobrino; BREMMB, João Matheus; MACÁRIO, Eduardo Marques; OLIVEIRA, Wanderson Kleber de; FRANÇA, Giovanni Vinícius Araújo de. COVID-19 epidemic in Brazil: where are we at?. **International Journal of Infectious Diseases**, v. 97, p. 382-385, 2020. DOI: <https://doi.org/10.1016/j.ijid.2020.06.044>.

MEYEROWITZ-KATZ, Gideon; BESANÇON, Lonni; FLAHAULT, Antoine; WIMMER, Raphael. Impact of mobility reduction on COVID-19 mortality: absence of evidence might be due to methodological issues. **Scientific Reports**, v. 11, n. 1, p. 1-9, 2021. DOI: <https://doi.org/10.1038/s41598-021-02461-2>.

MONTEIRO, Joana da Costa Martins; CARVALHO, Eduardo Fagundes de; GOMES, Ramón Chaves. Crime e policiamento durante a pandemia de COVID-19 no Rio de Janeiro, Brasil. **Ciência e Saúde Coletiva**, Rio de Janeiro, v. 26, n. 10, p. 4703-4714, 2021. DOI: <https://doi.org/10.1590/1413-812320212610.09352021>.

OLIVEIRA, Steevan. Pandemia e Crime: Revisão de Literatura Sobre os Impactos da Pandemia do Coronavírus na Incidência Criminal. **Revista Brasileira de Segurança Pública**, São Paulo, v. 16, n. 3, p. 32-57, 2022. DOI: <https://doi.org/10.31060/rbsp.2022.v16.n3.1457>.

PROVENZA, Marcello Montillo; COSTA, José Fabiano da Serra; NASCIMENTO, Carolina; TONASSI, Patrícia de Rezende; VERGARA, Thaís Lorena Díaz de. Análise estatística e previsão de séries temporais de roubos e furtos a transeuntes no município do Rio de Janeiro de 2009 a 2013. **Cadernos do IME - Série Estatística**, Rio de Janeiro, v. 39, n. 2, p. 1-34, 2015. DOI: <https://doi.org/10.12957/cadest.2015.20021>.

RAHIM, Karim John. **Applications of Multitaper Spectral Analysis to Nonstationary Data**. [s.l.], 2014. 210 f. Disponível em: <https://qspace.library.queensu.ca/server/api/core/bitstreams/9a1bf902-71ce-41ce-9aac-ec7438325ad4/content>. Acesso em: 5 out. 2023.

RIBEIRO, Vanessa dos Santos. A criminalidade na pandemia Covid-19 no Brasil: revisão integrativa. **Revista do Instituto Brasileiro de Segurança Pública (RIBSP)**, [s.l.], v. 5, n. 11, p. 134-143, 2022. DOI: <https://doi.org/10.36776/ribsp.v5i11.122>.

RIEDEL, Kurt; SIDORENKO, Alexander. Minimum bias multiple taper spectral estimation. **IEEE Transactions on Signal Processing**, [s.l.], v. 43, n. 1, p. 188-195, 1995. DOI: <https://doi.org/10.1109/78.365298>.

SHUMWAY, Robert; STOFFER, David. **Time series analysis and its applications: with R Examples**. 4. ed. Pittsburgh: Springer, 2016. E-book. Disponível em: <https://www.mimuw.edu.pl/~noble/courses/TimeSeries/RESOURCES/ShumwayStofferTimeSeries.pdf>. Acesso em: 30 abr. 2026.

STICKLE, Ben; FELSON, Marcus. Crime rates in a pandemic: the largest criminological experiment in history. **American Journal of Criminal Justice**, v. 45, n. 4, p. 525-536, 2020. DOI: <https://doi.org/10.1007/s12103-020-09546-0>.

STOICA, Petre; MOSES, Randolph. **Spectral Analysis of Signals**. Upper Saddle River: Prentice Hall, 2005. E-book. Disponível em: https://www.maths.lu.se/fileadmin/math/personal_staff/Andreas_Jakobsson/StoicaM05.pdf. Acesso em: 7 out. 2023.

VALENT, Jonas. Covid-19: governo declara transmissão comunitária em todo o país. **Agência Brasil**, Saúde, 20 mar. 2020. Disponível em: <https://agenciabrasil.ebc.com.br/saude/noticia/2020-03/covid-19-governo-declara-transmissao-comunitaria-em-todo-o-pais#:~:text=O%20Minist%C3%A9rio%20da%20Sa%C3%BAde%20publicou,valor%20em%20todo%20o%20pa%C3%ADs>. Acesso em: 30 abr. 2026.

VIRGÍLIO, Fernando; SANTIAGO, Marizângela Lissandra de Oliveira; NUNES, Renata Adele de Lima; BE-SERRA, Mabell Kallyne Melo; SENA, Francisco Thiago Carneiro; GOMES, Loyane Ellen Silva; MACENA, Raimunda Hermelinda Maia. Tendência temporal dos homicídios no Ceará, antes e durante a pandemia de Covid-19. **Journal of Health & Biological Sciences**, v. 10, n. 1, p. 1-6, 2022.

WHO – World Health Organization. **Coronavirus Disease (Covid-19) Pandemic**. Genebra, 2023. Disponível em: <https://www.who.int/emergencies/diseases/novel-coronavirus-2019>. Acesso em: 5 out. 2023.

ZHU, Fukang. Zero-inflated Poisson and negative binomial integer-valued GARCH models. **Journal of Statistical Planning and Inference**, v. 142, n. 4, p. 826-839, 2012. DOI: <http://dx.doi.org/10.1016/j.jspi.2011.10.002>.

ANEXO A

QUADRO 1

Principais funções e pacotes do R e respectivos parâmetros utilizados

TÉCNICA	FUNÇÃO/PARÂMETROS	PACOTE
Spectral Analysis	<code>spec.mtm(nw = 4, k = 7, dtUnits = "hour", Ftest = T, plot = F, jackknife = T, jkCIProb=.99)</code>	multitaper 1.0-15
ACF/PACF	<code>ggAcf(lag.max = 56, ci = 0.99)</code> <code>ggPacf(lag.max = 56, ci = 0.99)</code>	forecast 8.20
model/STL	<code>model(stl = STL(n, robust = TRUE))</code>	fabletools 0.3.2 feasts 0.3.0

Fonte: Elaborado pelos autores.