



UNIVERSIDADE ESTADUAL DE CAMPINAS
INSTITUTO DE ECONOMIA



MIQUÉIAS DA SILVA ARAÚJO

Modelos de previsão de índices de criminalidade do estado do Paraná

CAMPINAS - SP

2021

MIQUÉIAS DA SILVA ARAÚJO

Modelos de previsão de índices de criminalidade do estado do Paraná

Monografia apresentada ao Instituto de Economia da Universidade Estadual de Campinas como parte dos requisitos exigidos para a obtenção do título de Bacharel em Ciências Econômicas.

Orientador: Prof. Dr. Marcelo Justus dos Santos

CAMPINAS - SP

2021

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca do Instituto de Economia
Luana Araujo de Lima - CRB 8/9706

Ar15m Araújo, Miquéias da Silva, 1997-
Modelos de previsão de índices de criminalidade do estado do Paraná /
Miquéias da Silva Araújo. – Campinas, SP : [s.n.], 2021.

Orientador: Marcelo Justus dos Santos.
Trabalho de Conclusão de Curso (graduação) – Universidade Estadual de
Campinas, Instituto de Economia.

1. Crime - Aspectos econômicos. 2. Estatística criminal. 3. Crime - Paraná
(Estado). 4. Modelagem preditiva. 5. Previsão com metodologia de Box-Jenkins. I.
Santos, Marcelo Justus dos, 1977-. II. Universidade Estadual de Campinas.
Instituto de Economia. III. Título.

Informações adicionais, complementares

Titulação: Bacharel em Ciências Econômicas

Banca examinadora:

Marcelo Justus dos Santos [Orientador]

Temidayo James Aransiola

Data de entrega do trabalho definitivo: 21-11-2021

MIQUÉIAS DA SILVA ARAÚJO

Modelos de previsão de índices de criminalidade do estado do Paraná

Monografia apresentada ao Instituto de Economia da Universidade Estadual de Campinas como parte dos requisitos exigidos para a obtenção do título de Bacharel em Ciências Econômicas.

Data de aprovação: 07 / 12 / 2021

Banca Examinadora

Prof. Dr. Marcelo Justus dos Santos – Presidente da banca
Instituto de Economia da Universidade Estadual de Campinas

Dr. Temidayo James Aransiola – Pesquisador convidado
Instituto de Economia da Universidade Estadual de Campinas

Dedico esse trabalho à minha mãe Lucimar, e ao meu ao meu pai Francisco, que muito batalharam almejando meu desenvolvimento e sempre me apoiaram em minha caminhada pela vida acadêmica.

AGRADECIMENTOS

O desenvolvimento e conclusão desse trabalho não teria sido possível sem as ajudas que obtive. Primeiramente, agradeço a minha família por todo incentivo e motivação passados a mim.

Agradeço ao meu orientador Marcelo Justus por ter me guiado durante o processo de desenvolvimento desse trabalho, por todo o apoio oferecido, pela paciência e direcionamentos precisos que possibilitaram a realização dessa pesquisa.

Agradeço a todos os professores do Instituto de Economia da Unicamp, os quais contribuíram fortemente para o meu desenvolvimento pessoal e profissional, sendo também fontes de aprendizados e experiências que levarei comigo com orgulho.

“Os erros causados por dados inadequados são muito menores do que aqueles que se devem à total ausência de dados.” (Charles Babbage)

RESUMO

Esse trabalho parte da hipótese de que, entre as metodologias de previsão de variáveis, a metodologia Box-Jenkins é uma das metodologias que podem contribuir com a elaboração de modelos preditivos de índices de criminalidade, ajudando assim com o direcionamento eficiente de recursos. Diante disso, esse trabalho tem como objetivo geral encontrar e analisar os melhores modelos preditivos gerados pela metodologia Box-Jenkins ao ser aplicada em séries temporais de índices de criminalidade do estado do Paraná. Para tal fim, a pesquisa se inicia com uma revisão bibliográfica, apresentando as diferentes abordagens de estudos da criminalidade. Posteriormente é apresentada a metodologia Box-Jenkins, a qual é utilizada para a elaboração dos modelos preditivos. Após a apresentação da metodologia, por fim, tem-se a aplicação da metodologia Box-Jenkins às séries históricas de índices de criminalidade do estado do Paraná, os quais são divididos dois grupos: proxy de crimes contra o patrimônio (“furto de veículos”, “roubo de veículos”, o agregado “furto e roubo de veículos”) e proxy de crime contra pessoas (“homicídio doloso” e “latrocínio”). Nesse trabalho a principal limitação na análise dos resultados foram os efeitos que a pandemia desencadeou sobre a evolução dos índices de criminalidade. O isolamento social e as demais restrições necessárias para o combate a disseminação do covid-19 geraram um cenário distinto dos observados em períodos anteriores nas séries temporais escolhidas. Entretanto, foi efetivamente possível construir modelos de previsão por meio da metodologia Box-Jenkins, sendo mais assertivos os modelos construídos para os índices de “homicídio doloso” e “latrocínio”. Constatou-se também que a ocorrência da pandemia do covid-19 impactou de maneira diferente a ocorrência de registros de crimes, afetando com mais intensidade crimes contra o patrimônio (com acentuada redução de ocorrências) quando comparados a crimes contra pessoas.

Palavras-chave: Economia do crime. Criminalidade. Estado do Paraná. Modelos de previsão. Box-Jenkins.

ABSTRACT

This work starts from the hypothesis that, among the variable prediction methodologies, the Box-Jenkins methodology is one of the methodologies that can contribute to the elaboration of predictive models of crime indicators, thus helping with the efficient allocation of resources. Therefore, this work aims to find and analyse the best predictive models generated by the Box-Jenkins methodology when applied to time series of crime indicators in the state of Paraná. To this end, the research begins with a literature review, presenting the different approaches to crime studies. Afterwards, the Box-Jenkins methodology is presented, which is used for the elaboration of predictive models. After the presentation of the methodology, finally, there is the application of the Box-Jenkins methodology to the historical series of crime indicators in the state of Paraná, which are divided into two groups: crimes against property proxy ("theft of vehicles", "vehicle theft", the aggregate "vehicle theft and robbery") and a proxy for crime against people ("wrongful murder" and "robbery"). In this work, the main limitation in the analysis of the results was the effects that the pandemic unleashed on the evolution of crime indicators. Social isolation and other restrictions necessary to combat the dissemination of covid-19 generated a scenario different from those observed in previous periods in the chosen time series. However, it was effectively possible to build forecast models using the Box-Jenkins methodology, with the models built for the indicators of "intentional homicide" and "robbery" being more assertive. It was also found that the occurrence of the covid-19 pandemic had a different impact on the occurrence of crime records, affecting crimes against property more intensely (with a marked reduction in occurrences) when compared to crimes against people.

Keywords: Economy of crime. Criminality. State of Parana. Forecast models. Box-Jenkins.

SUMÁRIO

1	INTRODUÇÃO	11
2	REVISÃO BIBLIOGRÁFICA.....	13
2.1	Conceito de crime.....	13
2.2	Teorias da criminalidade	15
2.3	A literatura brasileira da economia do crime	18
2.4	Aplicações de estudos da economia do crime no estado do Paraná.....	21
3	METODOLOGIA BOX-JENKINS	23
3.1	Quando utilizar a metodologia Box-Jenkins	24
3.2	O procedimento de modelagem Box-Jenkins.....	26
3.3	Vantagens da metodologia Box-Jenkins	29
4	ANÁLISE DOS MODELOS PREDITIVOS	30
4.1	Conhecendo as séries escolhidas.....	30
4.2	Identificação do processo e estimação do modelo.	32
4.3	Diagnóstico dos resíduos.....	34
4.3.1	Teste de autocorrelação.....	34
4.3.2	Teste de heterocedasticidade	35
4.3.3	Teste de normalidade	35
4.4	Previsões das séries temporais	37
5	CONSIDERAÇÕES FINAIS	40
	REFERÊNCIAS	43

1 INTRODUÇÃO

Os estudos dedicados a compreensão aprofundada da criminalidade são recentes e nem mesmo exclusivos da economia. Muito se discute sobre o que leva um indivíduo a aderir a comportamentos que o enquadre como um criminoso, comumente sendo discutido se tal indivíduo nasce com precondições que o levam ao comportamento desviante ou se fatores externos, presentes no meio social, são os elementos decisivos para a realização de delitos (CERQUEIRA; LOBÃO, 2004). Diferentes áreas apresentam diferentes respostas a tais discussões, seja baseando-se em argumentos biológicos, psicológicos ou mesmo sociológicos. E mais recentemente, adentrou em tal seara estudiosos da economia, os quais buscam um melhor entendimento da criminalidade partindo de ferramentas e conceitos amplamente utilizados em estudos econômicos, contribuindo assim para um novo olhar sobre possíveis determinantes do crime (SANTOS; KASSOUF, 2008).

Esses diferentes estudos não se restringem à compreensão de elementos intensificadores da criminalidade na sociedade, mas também buscam alternativas que possibilitam a redução de tal fenômeno social responsável por perdas de bens materiais, e o mais importante, responsável por inestimáveis perdas de vidas humanas. No campo da economia, além do desenvolvimento de trabalhos que investigam possíveis impactos de variáveis econômicas sobre a intensificação da ocorrência de crime (ANDRADE; LISBOA, 2000; CARNEIRO, 2000; LUCAS et al., 2020), trabalhos que utilizam outras ferramentas, como as tratadas pela econometria, também podem contribuir com a elaboração de estratégias de combate ao crime. Tratando-se dessas ferramentas, pode-se citar as que propiciam a geração de modelos preditivos de índices de criminalidade. Tais ferramentas são grandes aliadas ao combate à criminalidade, uma vez que, sendo fornecidas previsões sobre comportamentos de índices de criminalidade, é possível uma aplicação mais eficaz de recursos, realocando-os em áreas estratégicas, obtendo assim melhores resultados em ações que visam a redução da ocorrência de crimes (ALVES, 2018; JOÃO, 2009).

Tendo como base o estudo econômico da criminalidade, esse trabalho tem como objetivo geral encontrar e analisar os melhores modelos preditivos gerados pela metodologia Box-Jenkins ao ser aplicada em séries temporais de índices de criminalidade do estado do Paraná. Para que tal objetivo seja alcançado, tem-se como primeiro objetivo específico a revisão bibliográfica, evidenciando diferentes teorias das causas da criminalidade e expondo os principais argumentos teóricos, desde os elaborados por estudiosos das Ciências Sociais às elaborados por estudiosos da Economia, expondo também em tal revisão os principais debates

teóricos entre a economia e a criminalidade e pesquisas desenvolvidas mais recentemente. O segundo objetivo específico é a apresentação da metodologia Box-Jenkins, a qual será utilizada para a elaboração dos modelos preditivos. Por fim, como terceiro objetivo específico, tem-se a aplicação da metodologia Box-Jenkins às séries históricas previamente coletadas de índices de criminalidade e a análise dos resultados obtidos com os modelos preditivos elaborados.

É sabido que o problema da criminalidade é um fenômeno social marcado por uma variedade de fatores que contribuem para seu aumento ou redução, muitas vezes estando relacionada a questões históricas de desigualdade social e reduzidas possibilidades de acesso ao sistema educacional e ingresso ao mercado de trabalho (GARRIDO, 2016; PROCÓPIO, 2014). Portanto, em meio a tal diversidade de fatores fica claro que o combate à criminalidade não deve ocorrer somente nas linhas de frente com o aporte de forças policiais e aplicação da lei. O combate à criminalidade deve também ser realizado por meio do controle das variáveis que contribuem com o aumento de atos inflacionários. A questão é que, tal modalidade de enfrentamento, nem sempre é possível devido às desconexões entre políticas públicas, restando em muitas das vezes apenas fazer o melhor proveito possível dos recursos que se encontram disponíveis para o enfrentamento dos problemas de segurança pública existentes. Pensando na otimização de tais recursos, veio as seguintes questões: como recursos destinados a segurança pública podem ser utilizados de forma mais eficiente? Além disso, seria a utilização de modelos preditivos uma alternativa viável a ser considerada na elaboração de planos de ação que tratam da segurança pública com recursos escassos? De tal questão veio a hipótese de que, entre as distintas metodologias de previsão de variáveis existentes, a metodologia Box-Jenkins é uma das metodologias que pode contribuir com a elaboração de modelos preditivos de índices de criminalidade, contribuindo assim com planejamentos estratégicos mais precisos e direcionamento mais eficiente de recursos na atuação contra a criminalidade.

O ponto de partida da pesquisa foi o levantamento bibliográfico, para o qual foram utilizados como fontes de informações livros e artigos científicos, não se restringindo a um período específico. Nessa etapa, os primeiros esforços foram dedicados à busca de obras de diferentes áreas do conhecimento a fim de expor as diferentes teorias da causa da criminalidade, além de apresentar trabalhos que contribuem para o debate teórico da relação entre economia e crime, explicitando os principais pontos de convergências e divergências. Após o levantamento bibliográfico, veio o momento da construção da base de dados utilizada nos modelos de previsão. Para a construção de tal base de dados, foram extraídas séries temporais de índices de criminalidade dos relatórios anuais disponibilizados pela Secretaria de Segurança Pública (SSP) do estado do Paraná, sendo dados de frequência mensal. Quanto a escolha do estado, essa foi

feita devido à disponibilização, por parte da SSP do Paraná, de informações que possibilitam a construção de modelos preditivos. Outra motivação para a escolha do Paraná e a baixa existência de estudo destinados a previsão de índices de criminalidade desse estado. Apesar de a SSP do Paraná disponibiliza dados importantes para a análise de séries temporais, os dados disponibilizados não puderam ser utilizados no formato original, tendo em vista serem armazenados em formato PDF. Assim, foi necessário a conversão das informações para um formato que favorece a manipulação dos dados, sendo adotado o formato xlsx na construção da base de dados desse trabalho.

Com o fim da coleta de dados, veio a etapa de apresentação da metodologia Box-Jenkins e dos passos que a compõe, evidenciando suas vantagens e desvantagens da utilização dessa metodologia na elaboração de modelos preditivos. Depois da apresentação, chegou-se na etapa de aplicação da metodologia Box-Jenkins afim de construir modelos de previsão com as séries temporais coletadas previamente, as quais são séries temporais de variáveis proxy de duas modalidades de crimes: contra pessoas e contra o patrimônio. Concluída a elaboração e testes dos modelos preditivos, passou-se para a exposição dos resultados das previsões e análise dos resultados gerados.

Essa pesquisa monográfica possui um caráter empírico, uma vez que o foco está na construção e análise de modelos preditivos, sendo esses construídos mediante a aplicação da metodologia Box-Jenkins e utilização de séries temporais de índices de criminalidade do estado do Paraná. E ao fim do trabalho, espera-se mostrar que modelos preditivos podem contribuir com o combate à criminalidade, bem como favorecer o processo de alocação de recursos em áreas e em momentos que geram resultados mais significativos na redução da ocorrência de crimes, colaborando assim com a elaboração de políticas públicas mais eficazes.

2 REVISÃO BIBLIOGRÁFICA

2.1 Conceito de crime

Émile Durkheim, em sua obra de 1893, “Da divisão do trabalho social”, define um crime como sendo “todo ato que, num grau qualquer, determina contra seu autor essa reação característica a que chamamos pena” (DURKHEIM, 1999: 39). Essa preocupação com as respostas oficiais está voltada para a questão do consenso social, portanto, Durkheim entende que “um ato é criminoso quando ofende os estados fortes e definidos da consciência coletiva” (DURKHEIM, 1999: 51), sendo necessário acrescentar que “não se deve dizer que um ato

ofenda a consciência comum por ser criminoso, mas que é criminoso porque ofende a consciência comum. ” (DURKHEIM, 1999: 52). Dessa forma, fica claro que Durkheim não interpreta a pena como sendo apenas uma “reação passional, de intensidade graduada, que a sociedade exerce por intermédio de um corpo constituído contra aqueles de seus membros que violaram certas regras de conduta” (DURKHEIM, 1999: 68).

A definição de crime apresentada por Durkheim refere-se ao comportamento definido como tal legalmente e que recebe suas sanções criminais legais. Assim, só é possível falar em crime com a existência de leis, também não sendo possível haver lei criminal sem que haja uma perda ou danos. Em resumo, Durkheim entende que o crime é o não cumprimento de normas estabelecidas socialmente que posteriormente leva a sanções previstas no direito criminal. Do ponto de vista do autor, a característica comum de um crime é o fato de serem comportamentos aos quais geralmente todos os membros da sociedade se opõem.

De acordo com o Sellin (1938), é possível falar em uma perspectiva multicultural do crime, que pode ser entendida como sendo a violação a duas modalidades de normas: normas de conduta e categorias universais. As normas de conduta são criações sociais e, portanto, podem apresentar diferenciações entre distintos grupos sociais. As categorias universais de crime, por sua vez, podem assumir significados similares em diferentes sociedades, como é o caso do homicídio, o qual é visto como crime em diversas formações sociais. Nesse debate sobre o conceito de crime, Sellin (1938) acrescenta que, apesar de as normas de condutas serem criadas pela sociedade, as normas jurídico-penais, ou seja, as que estabelecem por meio de decretos os comportamentos ditos criminosos, meramente agem de modo semelhante a uma projeção da estrutura normativa de grupos dominantes culturalmente. Como consequência dessa influência de grupos dominantes, as normas jurídico-penais são reflexo dos valores e interesses de grupos sociais que estão à frente do controle do aparelho legislativo.

Para Machado (2008), por a definição de crime não ser algo auto evidente e unitário, é importante notar que há a diversidade de elementos possivelmente associados à definição do que vem a ser criminalidade, como por exemplo, o relativismo cultural ou mesmo o relativismo histórico que o acompanha. Assim, Machado (2008) considera que existem três elementos básicos a considerar na definição de crime. O primeiro elemento se refere aos danos causados, o que remetem para a natureza, dimensão e severidade dos prejuízos e males causados e que tipo de vítimas foram atingidas. O segundo elemento trata-se do consenso social sobre os impactos criados pela ocorrência do crime. Por fim, o terceiro elemento faz menção às respostas oficiais, que consideram a existência de legislação criminal que determina as circunstâncias em

que um ato danoso pode ser classificado como crime e quais as sanções devem ser dirigidas a quem o cometeu.

2.2 Teorias da criminalidade

Como afirmado por Cerqueira e Lobão (2004), entender os comportamentos criminosos é uma tarefa árdua, uma vez que não há um consenso e existe diversas interpretações sobre os fatores que levam um indivíduo a ter um desvio de conduta e agir de forma criminosa. Entre os diferentes caminhos traçados por estudiosos das causas da criminalidade, Cerqueira e Lobão (2004) destacam que, de modo geral, pode-se agrupar esses diferentes trajetos em dois grandes grupos. No primeiro grupo, tem-se os estudos nos quais as motivações pessoais estão no foco dos fatores que levam ao comportamento criminoso. Já no segundo grupo, tem-se os estudos que buscam visibilizar processos externos aos indivíduos, mas que os levariam a tornarem-se criminosos. Esses dois grandes grupos podem ser desagregados em distintas linhas de pesquisas desenvolvidas em diferentes áreas do conhecimento, mas todas voltadas ao mesmo fim: a compreensão de elementos que evidenciam as causas da criminalidade.

Tratando-se dos estudos nos quais é entendido que o comportamento criminoso está associado a motivações pessoais, há trabalhos, tanto de biólogos como de psicólogos, que se baseiam no pensamento de que há características físicas ou mentais responsáveis por diferenciar indivíduos que cometem crimes daqueles que não cometem. Esses estudos foram fortemente disseminados ao longo do século XIX, momento no qual formou-se o chamado positivismo criminológico. De modo geral, o positivismo criminológico defendia que comportamentos criminosos podem ser causados por fatores biológicos, psicológicos e sociais, os quais eram considerados passíveis de observação e medição (MACHADO, 2008).

Em meio aos debates gerados pelo positivismo criminológico na área biológica, até meados do século XX, com base em pesquisas genéticas e evolutivas, foi predominante a ideia de que o comportamento criminoso é causado por atavismos físicos e intelectuais hereditários, que seriam reminiscências de estágios mais primitivo da evolução humana. Portanto, as teorias do crime apoiadas em conceitos biológicos se concentram nos fatores individuais que se consideram ou são característicos do corpo, buscando assim alcançar a compreensão dos determinantes biológicos do crime, em particular, a contribuição da genética como fator determinante. Já no domínio da psicologia e da psiquiatria, os estudos de determinantes da criminalidade centralizou-se nos traços de personalidade de um indivíduo, o que levou ao apoio de estudos e programas de tratamento e adaptação da personalidade de criminosos aos padrões

exigidos pela vida na sociedade. Esses estudos partem da suposição de que existem impulsos naturais que possivelmente entrariam em conflito com as resistências criadas pelo processo de socialização e mecanismos de indução de comportamentos considerados normais pelo meio social (MACHADO, 2008). Em resumo as explicações biológicas e psicológicas para as causas da criminalidade apoiavam-se na defesa tanto da presença de disfuncionalidades em genes quanto da presença de disfuncionalidades psíquicas, que seriam intrínsecas a criminosos. Entretanto, devido ao caráter e conteúdos frequentemente racistas, tais explicações das causas da criminalidade foram abandonadas após a Segunda Guerra (CERQUEIRA; LOBÃO, 2004).

Indo para estudos mais recentes desenvolvidos na área da psicologia, Gottfredson e Hirschi (1990), usando o conceito de autocontrole, argumentam que as pessoas têm diferenças no grau de autocontrole devido a elementos sociais, como por exemplo, o tipo de educação recebida, sendo também um fator interno. Para Gottfredson e Hirschi (1990), o crime é um comportamento que ocorre naturalmente se não for prevenido de forma adequada e por tal motivo entendem que a capacidade de autocontrole deve ser colocada em um indivíduo por meio da educação e treinamento. Para esses autores, o crime não é resultado do processo de socialização, uma vez que acreditam que criminosos são indivíduos antissociais desde a infância. Segundo os autores, por criminosos serem antissociais, eles não se submetem facilmente ao controle social, possuem pouca afinidade a comportamentos em grupos e há uma fraca conexão entre eles e outras pessoas ou projetos coletivos. Assim, o criminoso é visto como uma pessoa mal socializada e que não internalizou os aprendizados que podem proporcionar autocontrole. Desse modo, crime não é produzido socialmente, como nas teorias sociológicas positivistas, mas sim um comportamento natural que a sociedade deve evitar.

Ainda no século XX, dentro do grande grupo de estudo cujo foco está nas motivações individuais, surgiram novas metodologias de estudos sobre possíveis motivações que levam ao comportamento criminoso. Em meio a essas novas metodologias, veio o que passou a ser chamado de economia do crime, a qual buscava compreender os fenômenos da criminalidade mediante a utilização de conceitos e ferramentas típicos dos estudos econômicos. Um dos principais expoentes a ser destacado na economia do crime é o economista Gary Becker que segue a linha da teoria econômica da escolha racional.

O pressuposto da abordagem de Becker (1968) é o de que uma pessoa comete um crime se a utilidade esperada excede a utilidade que ela poderia obter por usar seu tempo e outros recursos em outras atividades. Assim, de acordo com essa abordagem, algumas pessoas tornam-se criminosos, não por suas motivações básicas diferirem das de outras pessoas, mas sim por terem custos e benefícios diferentes na prática criminosa, o que, apesar de ser uma linha de

pesquisa centrada no comportamento do indivíduo, demonstra claras distinções quanto aos estudos da biologia e psicologia do século XIX e início do século XX, onde a tendência a prática criminosa era vista como algo inato de certos indivíduos. Isaac Ehrlich é outro autor que segue alinhado das escolhas racionais. Em seu trabalho de 1973¹, Ehrlich tem como tese básica a ideia de que, na maioria das situações, os infratores respondem aos incentivos de modo semelhante à forma como demais pessoas respondem a incentivos ao se envolverem em atividades estritamente legítimas. Além disso, Ehrlich busca também tratar do papel da disponibilidade de oportunidades na determinação da escolha de um indivíduo de participar ou não de atividades ilegítimas.

Em relação ao grupo de pesquisas cujo foco está em processos que levam um indivíduo a cometer atos criminosos, é possível encontrar uma gama variada de abordagens baseadas na ideia de que as causas da criminalidade se encontram na própria sociedade, principalmente como resultado de pressões e tensões sociais. É importante notar que os métodos sociológicos do crime tendem a ser globais, envolvendo não apenas a explicação das causas do crime, mas também lidando com problemas da própria ordem social, entendendo as implicações político-criminais e descrevendo a forma, conteúdo e escopo de comportamento criminoso, bem como a relação entre teoria e prática no domínio da reinserção social e prevenção da criminalidade. Mas é justamente essa abordagem mais ampla trazida pela sociologia que possibilitou o desenvolvimento de novas abordagens que contribuiriam para o melhor entendimento do comportamento criminoso.

Uma dessas abordagens é a da teoria da desorganização social. Nessa teoria, tanto a organização social quanto a desorganização social formam laços indissociáveis de redes sistêmicas que facilitam ou inibem o controle social (SAMPSON, 1997). Nisso, a criminalidade é vista como resultado de efeitos indesejáveis no modo com o qual as relações sociais comunitárias e vizinhanças se organizam (ENTORF; SPENGLER, 2002), organizações relações sociais essas que podem se dar por meio redes de amizades esparsas, grupos de adolescentes sem supervisão ou orientação, ou baixa participação social. De modo geral, o que é evidenciado pela teoria da desorganização social é a existência de uma relação negativa entre coesão social e criminalidade.

A teoria da desorganização social possui também certa semelhança à teoria da associação diferencial, cujo enfoque maior está no processo de aprendizado social. Nessa teoria, que teve início com Sutherland (1973), busca-se analisar os processos pelos quais os indivíduos,

¹ EHRlich, I. Participation in Illegitimate Activities: A Theoretical and Empirical Investigation. *Journal of Political Economy*, v. 81, pp. 521-565, 1973.

principalmente os jovens, determinavam seus comportamentos a partir de suas experiências pessoais com relação a situações de conflito. De acordo com essa teoria, o comportamento favorável ou desfavorável ao crime seria apreendido através de interações pessoais, especialmente por meio do processo de comunicação (SUTHERLAND, 1973).

Outra teoria é a desenvolvida por Robert K. Merton (1958). Merton preocupou-se principalmente em descobrir como certas estruturas sociais exercem pressão específica sobre certas pessoas, motivando-as a se envolverem em comportamentos que não estão em conformidade com as normas tradicionais. Merton (1958) enfatizou a existência de uma necessidade de atingir objetivos culturalmente relacionados ao sucesso pessoal. Indivíduos que possuem como meta alcanças esses objetivos associados ao sucesso pessoal, mas não obtém sucesso nessa busca por meios considerados legítimos e que não internalizaram o controle normativo, podem ser impelidos a utilizar meios ilegais. Disso, Merton acredita que os indivíduos estão sujeitos ao crime porque a contradição entre a internalização de objetivos culturais relacionados ao sucesso pessoal causada por sua posição na estrutura social e a falta de meios legais para atingir esses objetivos o direcionou ao comportamento desviante. Segundo Cloward e Ohlin (1970), é necessário acrescentar que, além de um indivíduo não possuir acesso aos meios legais necessários para se alcançar as metas atribuídas a um sucesso pessoal, os indivíduos também devem estar em uma subcultura que o supra com meios ilegais de se alcanças os objetivos requeridos.

Walter B. Miller (1970) chega a conclusões semelhantes às apresentadas por Merton (1958). Analisando atos de violação da lei cometidos na rua por adolescentes de classes baixas, Miller conclui que a motivação dos atos inflacionários desses jovens vem da tentativa de aderir a formas de comportamento que os ajudariam a conquistar metas, estados, condições e padrões definidos pelo grupo social ao qual fazem parte e valorizados pelo meio cultural mais próximo.

2.3 A literatura brasileira da economia do crime

No estudo econômico das causas da criminalidade, é possível encontrar linhas de pesquisas que vão de encontro tanto aos argumentos que enfatizam as motivações pessoais na determinação de comportamentos desviantes, como é o caso dos trabalhos de Gary Becker baseados no princípio da escolha racional, quanto aos argumentos que buscam no meio social os elementos responsáveis por levar um indivíduo a cometer atos criminosos. Recentemente, as investigações econômicas sobre as causas da criminalidade tenderam a seguir essa última linha argumentativa, com a frequente utilização e indicadores sociais, econômicos e utilização de

técnicas econométricas afim de investigar as diferentes relações e correlações entre desenvolvimento social e criminalidade. É claro que, na economia, a utilização de técnicas econométricas não é o único meio utilizado para se entender as diferentes variáveis que podem impactar em índices de criminalidade. Muitas vezes se faz necessário a utilização conceitos de diferentes áreas, principalmente da sociologia, a qual em muito contribui para a fundamentação teórica dos trabalhos desenvolvidos na chamada economia do crime.

Apesar das limitações vindas da ausência de dados passíveis de serem utilizados em estudos empíricos, a literatura brasileira vem avançando nos estudos econômicos da causa da criminalidade. Entre os autores brasileiros, pode ser citado o trabalho de Andrade e Lisboa (2000), o qual busca analisar a evolução da taxa de homicídio nos Estados de Minas Gerais, Rio de Janeiro e São Paulo entre os anos de 1981 e 1997, almejando particularmente a verificação da existência de relação entre essa evolução e variáveis econômicas como salário real, desemprego, índice de Gini, entre outras. Como resultado da pesquisa, Andrade e Lisboa (2000) mostram que um aumento do salário real e uma queda da desigualdade geram redução da taxa de homicídio, a qual é usada como proxy de grau de criminalidade.

Merece destaque também o trabalho de Carneiro (2000), que busca desenvolver o olhar econômico sobre a criminalidade e compreender com mais profundidade a relação entre economia e crime nos estados brasileiros. Carneiro (2000) aponta a possibilidade de o impacto das variáveis econômicas sobre a parcela da população que se dedica a atividades ilegais seja diferenciado ao longo do ciclo de vida. Tal autor afirma que, para um jovem, a diferença entre as atividades legais e ilegais pode ser menor do que para um homem mais velho que participa do mercado de trabalho legal. Nesse caso, as variáveis econômicas podem ter um impacto maior sobre os jovens do que sobre os mais velhos. Uma possível interpretação desse resultado relaciona a idade da geração e a parcela dedicada às atividades ilegais. Indivíduos mais jovens se moveriam das atividades legais para as ilegais com maior facilidade do que os mais velhos, e esse movimento seria influenciado pelas variáveis econômicas. O aumento da população dedicada às atividades ilegais, por sua vez, resultaria em maiores taxas de homicídio.

Fajnzylber Araujo Junior (2001) é outro autor que avança no estudo das causas da criminalidade se baseando na existência de determinantes socioeconômicos. Para Fajnzylber, há sim indício de uma relação estreita entre desigualdade, pobreza e mobilidade social, de um lado e taxa de homicídios de outro, que é usada pelo autor como proxy do nível de criminalidade. Apesar de tais resultados em seus estudos, Fajnzylber reconhece a necessidade de estudos mais detalhados, uma vez que, se tratando da relação entre desigualdade e crime, por exemplo, é possível argumentar que não é a desigualdade de renda que impacta a

criminalidade, e sim outras características a ela relacionada, como a capacidade de proteção privada ou a desigualdade na distribuição dos esforços de segurança pública, ou mesmo a desigualdade na distribuição da educação ou na distribuição de riquezas.

Já Mendonça (2000), seguindo o modelo das escolhas racionais, parte da tese de que o agente possui um consumo referencial imposto pelos padrões da sociedade, o que pode gerar um componente de insatisfação quando o consumo não satisfeito. Disso, utiliza a análise elaborada por Becker (1968) num contexto de maximização intertemporal afim de demonstrar que o retorno exigido pelo agente para levar a cabo uma atividade ilícita é reduzido por uma quantidade diretamente relacionada com o seu grau de insatisfação. Utilizando dados de painel para estados brasileiros no período de 1985 a 1995, Mendonça testa a influência que a desigualdade social tem sobre o fenômeno da criminalidade, chegando a conclusão de que a desigualdade social representada pelo índice de Gini exerce impacto positivo sobre a criminalidade no caso brasileiro.

Debruçando-se sobre os determinantes da criminalidade no Rio Grande do Sul e em especial, os efeitos da desigualdade, Oliveira (2008) apresenta um modelo econométrico que, além de seguir as contribuições da economia do crime, acrescenta as contribuições da abordagem ecológica e as teorias do aprendizado social. Em seu trabalho, Oliver destaca o papel da desigualdade de renda como fator que potencializa a criminalidade mostrando a dinâmica advinda do aumento da renda dos mais ricos e o aumento da renda dos mais pobres. O resultado é que o aumento da renda dos mais ricos apresentam uma correlação positiva com o número de roubos e furtos enquanto o aumento da renda dos mais pobres apresenta correlação negativa com número de homicídios, ou seja, a conclusão é a de que o crescimento da renda só resulta em aumento da criminalidade quando o crescimento da renda não beneficia os mais pobres e intensifica das desigualdades sociais.

Tratando de estudos mais recentes, tem-se o trabalho de Gaulez e Maciel (2015), que analisa possíveis determinantes da criminalidade para o estado de São Paulo no ano de 2011 utilizando a variável “crimes contra patrimônio” como *proxy* para a criminalidade. O uso de técnicas de econometria espacial contribuiu para que fosse possível mostrar que renda, densidade demográfica e grau de urbanização afetam positivamente a criminalidade. Não só isso, baseando-se também na teoria da escolha racional, os autores apresentaram indícios de que o crime contra o patrimônio ocorre onde o retorno esperado é maior.

Moreira e Fochezatto (2017) são outros autores que fazem uso da econometria espacial afim de estudar a criminalidade. Por meio da criação de um índice de criminalidade dos municípios do estado da Bahia com dados de 2014, buscaram examinar os determinantes da

criminalidade, além de elementos que ajudassem a explicar a dinâmica da violência e o padrão de organização espacial nos municípios do estado baiano. Com os resultados que obtiveram, apresentaram evidências de que municípios podem ser afetados por municípios vizinhos no quesito atividades criminosas, por ocorrer o que chamaram de mecanismo de transbordamento e transferências da criminalidade.

Referindo-se a trabalhos que envolve a utilização de modelos preditivos aplicados a indicadores de criminalidade, pode ser encontrado trabalhos como o de Araújo, Provenza e Costa (2021) que, buscando um melhor entendimento do contexto da violência letal, analisa dos números mensais de homicídios do estado do Rio de Janeiro. Nesse trabalho, usando como fonte o Instituto de Segurança Pública do Rio de Janeiro, são coletados dados dos números de homicídios ocorridos de janeiro de 2000 a dezembro de 2020. Com o intuito de encontrar a melhor ferramenta de construção de modelos preditivos, esses dados foram posteriormente aplicados em modelos de Estado e Suavização Exponencial (ETS), Redes Neurais Autoregressivas (AR-NN) e Autorregressivo Integrado de Média Móveis (ARIMA) aplicados à metodologia Box-Jenkins. Com o fim dos testes, chegou-se à conclusão de que, através das métricas de previsão (MAE, MRSE e MAPE), o ETS foi o modelo estatístico que melhor se ajustou aos dados.

Outros trabalhos, como o de Teixeira (2006), dão maior ênfase à capacidade da metodologia Box-Jenkins. Utilizando a metodologia Box-Jenkins, Teixeira (2006) constrói modelos preditivos de índices de criminalidade por 1000 habitantes de três cidades do Sul de Minas Gerais: Lavras, Alfenas e Varginha. Para tal construção foram utilizadas as séries temporais crimes Contra a Pessoa e crimes Contra o Patrimônio, sendo ambas as séries constituídas por dados mensais correspondentes ao período de janeiro de 1991 a junho de 2005. Com o fim da aplicação da metodologia Box-Jenkins, constatou-se que os resultados das previsões fornecidas por tal metodologia são próximos dos valores reais observados, mostrando, portanto, que a metodologia utilizada é útil para a orientação de políticas públicas e controle dos índices estudados. Resultado semelhante foi encontrado pelo trabalho de Melo (2019), que, usando a metodologia Box-Jenkins, produziu modelos preditivos do número de ocorrências de homicídios dolosos consumados em Cuiabá e Várzea Grande, chegando assim a modelos capazes de prever com grande acurácia os casos de homicídios nas regiões selecionadas.

2.4 Aplicações de estudos da economia do crime no estado do Paraná

Tratando-se dos trabalhos mais recentes que abordam o estudo das causas da criminalidade do estado do Paraná por meio da economia, em grande parte, tais trabalhos têm seguido por rotas semelhantes, fazendo uso constante da econometria espacial. Sass, Porsse e Silva (2016), por exemplo, debruçando-se sobre a análise espacial e fazendo uso de dados dos municípios do estado paranaense, buscam identificar os fatores que influenciam as taxas de homicídios. O método utilizado, a Análise Exploratória de Dados Espaciais (AEDE), ajudou a identificar padrões de autocorrelação espacial nas taxas de homicídio (proxy para criminalidade) no Paraná, mostrando que os municípios com altas taxas de possuem vizinhos com altas taxas de homicídio. E por meio de estimação de modelos espaciais globais (SAR e SDM), puderam ainda apontar que o grau de urbanização, taxa de pobreza, além das defasagens espaciais do grau de urbanização, da densidade demográfica, da taxa de pobreza e da taxa de homicídios, são algumas das variáveis que mais impactar nas taxas de homicídios.

Plassa e Parré (2019) são outros autores que fizeram uso da econometria espacial para estudar a distribuição espacial das taxas de homicídios no Paraná. Baseando-se na teoria da desorganização social e buscando entender o impacto de variáveis socioeconômicas nas taxas de homicídios do estado do Paraná no período de 2010, esses autores elaboraram modelos de econometria espacial com os quais mostraram haver uma dependência espacial positiva entre os municípios paranaenses e as taxas de homicídio, verificando, por exemplo, que as taxas de homicídios mais altas no estado estão concentradas na capital e na fronteira com o Paraguai. Ainda sobre a dependência espacial, apresentam também resultados semelhantes aos apresentados por Sass, Porsse e Silva (2016), com a demonstração de que municípios com altas taxas de homicídios estão cercados por municípios com situação semelhante nessa modalidade de crime contra a pessoa. Já com o intuito de entender as altas taxas de homicídios em certas regiões do estado, produziram fatores socioeconômicos, nos quais a desvantagens concentradas e instabilidade residencial tiveram um impacto positivo e significativo sobre as taxas de homicídios no estado, o que condiz aos argumentos da teoria da desorganização social.

Lucas, Cunha e Bondezan (2020) são autores que chegam a resultados semelhantes aos de Sass, Porsse e Silva (2016), expondo que as regiões mais urbanizadas são as com maiores taxas de homicídios por agressão. Mas não estando relacionada apenas a urbanização, demonstraram que as maiores taxas de homicídios por agressão estão em regiões com elevado percentual de população jovem masculina, com grande nível de desigualdade econômica e com altas taxas de desemprego e atraso escolar, corroborando com os demais resultados da literatura, como os apresentados por Gaulez e Maciel (2015). Esses resultados são importantes para mostrar como a urbanização e a desigualdade impactam a índices de criminalidade e indicam a

urgência que é diminuir a desigualdade econômica e a pobreza para reduzir as taxas de crimes dos municípios do Paraná.

Shikida et al. (2006) se distanciam da econometria espacial e partem para a aplicação de questionários antes de irem à econometria. Para analisar determinantes do comportamento criminoso, utilizam dados obtidos via aplicação de questionários/entrevistas no interior das Penitenciárias Central de Piraquara (PCP), Estadual de Piraquara (PEP) e Feminina de Piraquara (PFP). Na análise perceberam que são mais propensos ao uso da violência na atividade criminosa os jovens do sexo masculino, com ensino médio, sem confiança no papel da justiça, que têm parceiro para as atividades criminosas e que possuem arma de fogo. Tratando-se desse último fator, a posse de arma de fogo foi um dos principais fatores ligados ao comportamento violento na atividade criminosa, uma vez que eleva em mais de 70% as chances de ocorrência de tal comportamento.

Seguindo com pesquisas aplicadas em penitenciárias paranaenses, Gonçalves Júnior e Shikida (2013) analisaram os determinantes da criminalidade, mas focando especificamente em fatores que contribuem a reincidência penal de réus já julgados e condenados por crimes econômicos no Complexo de Penitenciárias de Piraquara (Paraná). Entre os resultados obtidos, o principal encontrado é o de que, para os reincidentes, e adotando os pressupostos da escolha racional, o crime compensa mais do que o trabalho lícito, com frequência acentuada em três modalidades de crimes: furto (66 vezes mais chance de reincidência), tráfico de drogas (7,9 vezes mais chance de reincidência) e roubo (6,2 vezes mais chance de reincidência). A pesquisa aponta também que, recuperar a base familiar e escolar do cidadão, juntamente com o fortalecimento das instituições polícia, justiça e Estado, são fatores que podem contribuir com a minimização da reincidência penal.

3 METODOLOGIA BOX-JENKINS

A metodologia Box-Jenkins recebe esse nome por ter sido originalmente desenvolvida por George E. P. Box e Gwilym M. Jenkins (1976), que aplicavam modelos de média móvel integrada autorregressiva (ARIMA) com o intuito de construir ajustes e posterior previsões de séries temporais univariadas. Nessa etapa do trabalho, a apresentação da metodologia Box-Jenkins baseia-se no exposto por Pankratz (2009), o qual expõe que todos os métodos de previsão estatística são de natureza irruptiva, ou seja, envolvem a projeção de padrões ou relacionamentos passados no futuro. No caso da previsão baseada na metodologia Box-Jenkins, padrões passados são extrapolados dentro de uma única série de dados para o futuro. Box e

Jenkins (1976) propõem uma família inteira de modelos, chamados modelos ARIMA, que parecem aplicáveis a uma ampla variedade de situações. Eles também desenvolveram um procedimento prático para escolher um modelo ARIMA apropriado fora dessa família de modelos ARIMA.

Em alguns tipos de análise estatística, as várias observações dentro de uma única série de dados são consideradas estatisticamente independentes. Esta é uma suposição padrão sobre o termo de erro (e , portanto, sobre as observações sobre a variável dependente) na análise de regressão tradicional. Mas na metodologia Box-Jenkins, supomos que as observações sequenciadas no tempo em uma série de dados $(\dots, z_{t-1}, z_t, z_{t+1}, \dots)$ podem ser estatisticamente dependentes. Usa-se o conceito estatístico de correlação para medir as relações entre as observações dentro da série. Na análise baseada na metodologia Box-Jenkins, objetiva-se examinar a correlação entre z no tempo t (z_t) e z em períodos de tempo anteriores ($z_{t-1}, z_{t-2}, z_{t-3}, \dots$).

3.1 Quando utilizar a metodologia Box-Jenkins

A metodologia de análise Box-Jenkins é especialmente adequada para previsões de curto prazo, tendo em vista que a maioria dos modelos ARIMA enfatiza fortemente o passado recente, e não o passado distante. Por exemplo, não é incomum ver um modelo ARIMA em que z_t está relacionado explicitamente apenas às duas observações mais recentes (z_{t-1} e z_{t-2}). Por outro lado, os modelos ARIMA que mostram z_t explicitamente relacionado a observações muito longínquas, como z_{t-70} ou z_{t-115} são, de fato, raros. Essa ênfase no passado recente significa que as previsões de longo prazo dos modelos ARIMA são menos confiáveis do que as previsões de curto prazo. Por exemplo, considere um modelo ARIMA onde z_t está relacionado explicitamente ao valor mais recente z_{t-1} . Seja n o último período para o qual os dados estão disponíveis. Para prever z_{n+1} (um período à frente), usa-se o valor mais recente z_n . Para prever z_{n+2} (dois períodos à frente), busca-se a observação mais recente z_{n+1} , que não está disponível; assim, deve-se usar a previsão de z_{n+1} no lugar do valor observado para aquele período. Obviamente, as previsões para o período $n + 2$ e além são menos confiáveis do que a previsão para o período $n + 1$, uma vez que se baseiam em informações menos confiáveis (ou seja, previsões em vez de observações).

Embora o método Box-Jenkins possa lidar com dados discretos ou contínuos, ele lida apenas com dados medidos em intervalos de tempo discretos e igualmente espaçados. Por exemplo, considere uma máquina eletrônica que mede a pressão em um tanque continuamente.

Um medidor conectado à máquina produz uma leitura a cada momento no tempo, e uma caneta mecânica registra continuamente os resultados em uma tira de papel em movimento. Esses dados não são apropriados para o método Box-Jenkins porque são medidos continuamente, em vez de em intervalos de tempo discretos. No entanto, se a pressão do tanque fosse registrada uma vez a cada hora, a série de dados resultante poderia ser analisada com a técnica Box-Jenkins.

Os dados medidos em intervalos de tempo discretos podem surgir de duas maneiras. Primeiro, uma variável pode ser acumulada ao longo do tempo e o total registrado periodicamente. Por exemplo, o valor em dólares de todas as vendas em uma taverna pode ser totalizado no final de cada dia, enquanto toneladas de produção de aço podem ser acumuladas e registradas mensalmente. Em segundo lugar, dados desse tipo podem surgir quando uma variável é amostrada periodicamente. O registro das leituras da pressão do tanque uma vez a cada hora (conforme discutido no último parágrafo) é um exemplo dessa amostragem. Ou suponha que um analista de investimentos registre o preço de fechamento de uma ação no final de cada semana. Nestes dois últimos casos, a variável está sendo amostrada em um instante no tempo, em vez de ser acumulada ao longo do tempo.

A construção de um modelo ARIMA, aplicado na metodologia Box-Jenkins, requer um tamanho de amostra adequado. Box e Jenkins (1976) sugerem que cerca de 50 observações é o número mínimo necessário. Alguns analistas podem ocasionalmente usar um tamanho de amostra menor, interpretando os resultados com cautela. Um grande tamanho de amostra é especialmente desejável ao trabalhar com dados sazonais, para os quais a metodologia Box-Jenkins também é particularmente úteis.

A metodologia Box-Jenkins se aplica apenas a séries de dados estacionários. Uma série temporal estacionária tem funções de média, variância e autocorrelação constantes ao longo do tempo. A suposição de estacionariedade simplifica a teoria subjacente aos modelos Box-Jenkins e ajuda a garantir que seja possível obter estimativas úteis de parâmetros a partir de um número moderado de observações. Por exemplo, com 50 observações, é possível obter uma estimativa razoavelmente boa da verdadeira média subjacente a uma série de dados se houver apenas uma média. Mas se a variável em questão tem uma média diferente a cada período de tempo, não seria possível obter estimativas úteis de cada média, pois normalmente tem-se apenas uma observação por período de tempo.

A média de uma série estacionária indica o nível geral da série. A média da amostra (\bar{z}) de uma série temporal é calculada como qualquer média aritmética comum. Ou seja, soma-se

as observações para cada período de tempo (z_t) e divide-se pelo número total de observações (n):

$$\bar{z} = \frac{1}{n} \sum_{t=1}^n z_t \quad (1.1)$$

Se uma série temporal for estacionária, a média de qualquer subconjunto principal da série não difere significativamente da média de qualquer outro subconjunto principal da série.

Usa-se a variância da amostra s_z^2 de uma série de tempo para estimar a verdadeira variância subjacente σ_z^2 . Como de costume, a variância mede a dispersão das observações em torno da média. A variância da amostra de uma série temporal é calculada como qualquer variância, ou seja, encontrando o desvio de cada observação da média, elevando ao quadrado cada desvio, somando os desvios e dividindo pelo número total de observações (n):

$$s_z^2 = \frac{1}{n} \sum_{t=1}^n (z_t - \bar{z})^2 \quad (1.2)$$

Claramente, se z_t , as observações se agrupam em torno de \bar{z} , então s_z^2 será relativamente pequeno, uma vez que cada desvio quadrado individual $(z_t - \bar{z})^2$ será pequeno.

Se uma série de dados for estacionária, a variação de qualquer subconjunto principal da série será diferente da variação de qualquer outro subconjunto principal apenas por acaso. O requisito de estacionariedade pode parecer bastante restritivo. No entanto, a maioria das séries não estacionárias que surgem na prática pode ser transformada em séries estacionárias por meio de operações relativamente simples.

3.2 O procedimento de modelagem Box-Jenkins

Pankratz (2009) faz duas considerações sobre a metodologia Box-Jenkins. Primeiro, as observações em uma série temporal podem estar estatisticamente relacionadas a outras observações na mesma série. Segundo, o objetivo na análise proposta por Box e Jenkins é encontrar uma boa maneira de afirmar essa relação estatística, ou seja, encontrar um bom modelo que descreva como as observações em uma única série temporal estão relacionadas entre si.

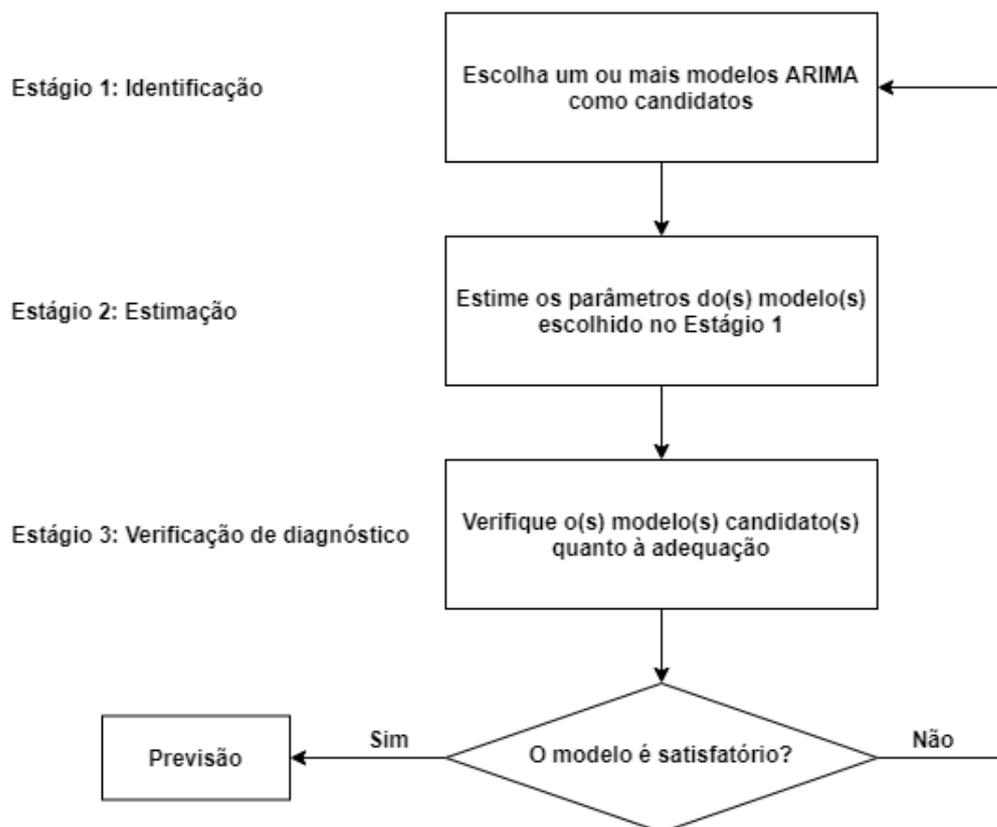
Um modelo ARIMA é uma declaração algébrica que mostra como uma variável de série temporal (z_t) está relacionada a seus próprios valores anteriores ($z_{t-1}, z_{t-2}, z_{t-3}, \dots$). Como exemplo, considere a expressão algébrica.

$$z_t = C + \phi_1 z_{t-1} + \alpha_t \quad (1.3)$$

A equação (1.3) é um exemplo de um modelo ARIMA. Ela mostra que z está relacionado ao seu próprio valor imediatamente passado z_{t-1} . C é um termo constante. ϕ_1 é um coeficiente fixo cujo valor determina a relação entre z_t e z_{t-1} . O termo α_t é um elemento de “choque” probabilístico. Os termos C , $\phi_1 z_{t-1}$ e α_t são componentes de z_t . C é um componente determinístico (fixo), $\phi_1 z_{t-1}$ é um componente probabilístico, pois seu valor depende em parte do valor de z_{t-1} , e α_t é um componente puramente probabilístico. Juntos, C e $\phi_1 z_{t-1}$ representam a parte previsível de z_t enquanto α_t é um elemento residual que não pode ser previsto dentro do modelo ARIMA. Vale lembrar que um bom modelo inclui o menor número de parâmetros estimados necessários para se ajustar adequadamente aos padrões nos dados disponíveis.

Box e Jenkins (1976) propõem um procedimento prático de três estágios para encontrar um bom modelo. O procedimento Box-Jenkins de três etapas é resumido esquematicamente na Figura 3.1.

Figura 3.1 - Estágios na abordagem interativa de Box-Jenkins para a construção de modelos. Extraído de Pankratz (2009).



Fonte: Extraído de Pankratz (2009).

O primeiro estágio é o de identificação. Nesse estágio, são usados dois dispositivos gráficos para medir a correlação entre as observações dentro de uma única série de dados. Esses dispositivos são chamados de função de autocorrelação (FAC) e função de autocorrelação parcial (FACP). O FAC e o FACP estimados medem as relações estatísticas dentro de uma série de dados de uma forma um tanto rudimentar (estatisticamente ineficiente). No entanto, eles são úteis para dar uma ideia dos padrões dos dados disponíveis. A próxima etapa no estágio de identificação é resumir as relações estatísticas dentro da série de dados de uma forma mais compacta do que a feita pelo FAC e FACP estimados. Box e Jenkins (1976) sugerem toda uma família de afirmações algébricas (modelos ARIMA) que podem ser escolhidas. A equação (1.3) é um exemplo de tal modelo.

O FAC e o FACP estimados são usados como guias para escolher um ou mais modelos ARIMA que pareçam apropriados. A ideia básica é esta: todo modelo ARIMA tem um FAC e um FACP teóricos associados a ele. Na fase de identificação, é feita a comparação dos FAC e FACP estimados a partir dos dados disponíveis com vários FAC e FACP teóricos. Em seguida, é escolhido provisoriamente o modelo cujo FAC e FACP teóricos se assemelham mais aos FAC e FACP estimados da série de dados. De qualquer modo, seja qual for o modelo que escolhido no estágio de identificação, esse modelo é apenas provisoriamente, ou seja, ele é apenas um candidato ao modelo final. Para escolher um modelo final, é necessário passar para os próximos dois estágios e talvez retornar ao estágio de identificação se o modelo provisoriamente considerado se mostrar inadequado.

No segundo estágio, são obtidas estimativas precisas dos coeficientes do modelo escolhido na fase de identificação. Por exemplo, escolhendo provisoriamente a equação (1.3) como modelo, ajusta-se esse modelo à série de dados disponíveis para obter estimativas de ϕ_1 e C . Esse estágio fornece alguns sinais de alerta sobre a adequação de nosso modelo. Em particular, se os coeficientes estimados não satisfazem certas condições de desigualdade matemática, esse modelo é rejeitado.

O terceiro estágio corresponde a etapa de verificação de diagnóstico (ou diagnóstico dos resíduos). Box e Jenkins (1976) sugerem algumas verificações de diagnóstico para ajudar a determinar se um modelo estimado é estatisticamente adequado. Um modelo que falha nesses testes de diagnóstico é rejeitado. Além disso, os resultados nesta fase também podem indicar como um modelo pode ser melhorado. Quando tal identificação é feita, volta-se ao estágio inicial, repedindo os ciclos de identificação, estimativa e verificação diagnóstica até encontrar um bom modelo final. Conforme mostrado na Figura 3.1, uma vez encontrado um modelo satisfatório, pode-se usá-lo para fazer previsões.

A natureza iterativa do procedimento de modelagem Box-Jenkins de três estágios é importante. Os estágios de estimativa e verificação de diagnóstico fornecem sinais de alerta informando quando e como um modelo deve ser reformulado. Assim, é dada continuidade as reidentificações, reestimativas e verificações até alcançar um modelo que seja satisfatório de acordo com vários critérios.

3.3 Vantagens da metodologia Box-Jenkins

Tratando-se do comparativo da abordagem Box-Jenkins frente a outros modelos, Pankratz (2009) destaca que a metodologia Box-Jenkins tem três vantagens sobre muitos outros métodos tradicionais de série única. Primeiro, os conceitos associados aos modelos Box-Jenkins são derivados de uma base sólida da teoria de probabilidade clássica e estatística matemática. Muitos outros métodos univariados historicamente populares são derivados de uma forma ad hoc ou intuitiva. Em segundo lugar, os modelos ARIMA são uma família de modelos, não apenas um único modelo. Box e Jenkins desenvolveram uma estratégia que orienta o analista na escolha de um ou mais modelos apropriados dessa família maior de modelos. Terceiro, pode-se mostrar que um modelo ARIMA apropriado produz previsões univariadas ótimas. Ou seja, nenhum outro modelo de série única padrão pode fornecer previsões com um erro de previsão médio quadrático (ou seja, variância do erro de previsão) menor. Em suma, parece haver um consenso geral entre profissionais experientes de que os modelos Box-Jenkins adequadamente construídos podem lidar com uma ampla variedade de situações e fornecer previsões de curto prazo mais precisas do que qualquer outra técnica padrão de série única. No entanto, a construção de modelos Box-Jenkins adequados pode exigir mais experiência e tempo de computador do que alguns métodos univariados historicamente populares.

Pankratz (2009) acrescenta que, os modelos de série única (univariados) diferem dos modelos de séries múltiplas (multivariados). O último envolve uma sequência de observações em pelo menos uma variável diferente daquela que está sendo prevista. Os modelos de séries múltiplas devem teoricamente produzir melhores previsões do que os modelos de série única porque as previsões de séries múltiplas são baseadas em mais informações do que apenas os valores anteriores da série que está sendo prevista. Entretanto, alguns analistas argumentam que, na prática, os modelos Box-Jenkins frequentemente se aproximam ou excedem a precisão da previsão de modelos de séries múltiplas, especialmente em previsões de curto prazo.

4 ANÁLISE DOS MODELOS PREDITIVOS

A seguir, é apresentada a análise preliminar de cinco índices de criminalidade, todos eles representando a quantidade de registros criminais realizados em cada um dos casos perante as autoridades policiais do estado do Paraná. Tais índices foram analisados mediante a utilização de ferramentas disponibilizadas pela linguagem de programação R. Quanto ao intervalo temporal, as séries completas abrangem o período de janeiro de 2012 a junho de 2021, entretanto, em decorrência dos impactos causados pela pandemia, esses índices de criminalidade sofreram grandes modificações em seus comportamentos padrão. Dessa forma, a fim de construir os modelos preditivos sem a interferências das alterações causadas pela a pandemia, foi considerado apenas o período anterior ao início os primeiros casos de covid-19 no Brasil, focando dessa forma no intervalo entre janeiro de 2012 e fevereiro de 2020.

4.1 Conhecendo as séries escolhidas

Para a construção dos modelos preditivos foram utilizadas séries temporais de frequência mensal de cinco índices de criminalidade compilados pela Secretaria de Segurança Pública do Paraná. Os índices escolhidos foram: “furto de veículos”, “roubo de veículos”, o agregado de “furto e roubo de veículos”, “homicídio doloso” e “latrocínio”. Os dois primeiros índices mais o agregado de ambos foram escolhidos como proxy da ocorrência de crimes contra o patrimônio. Quanto aos índices restantes, foram selecionados por como proxy de crime contra pessoas.

A evolução das séries selecionadas pode ser vista na Figura 4.1. Na série “furto de veículos”, é perceptível um crescimento do número de ocorrências registradas, mas marcado por oscilações que evidenciam a sazonalidade da série. De 2015 a 2016, o crescimento de novos registros de furtos de veículos ocorre de forma acentuada, alcançando um valor superior a 1800 registros de veículos furtados em 2016. Tal situação não se mantém, e nos meses seguintes, têm início o processo de declínio dos registros, os quais alcançam valores mensais inferiores a 1400 em 2020.

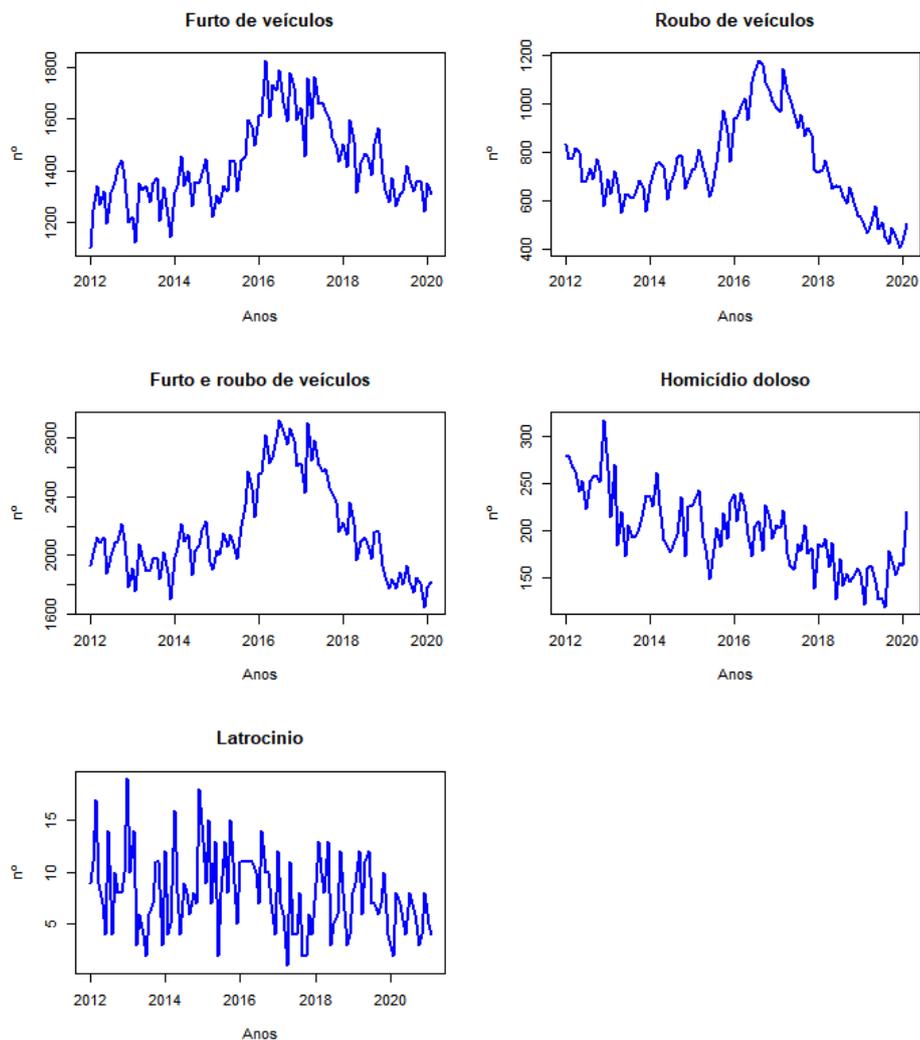
O indicador “roubo de veículos” apresenta uma evolução semelhante à série anterior, sendo marcada também por sazonalidade. Uma das diferenças está no movimento registrado de 2012 a 2013. Diferindo da série “furto de veículos”, nesse período, houve uma redução da ocorrência de registro de roubos. Somente a partir do segundo semestre de 2013 se inicia o

aumento de registros, alcançando o valor máximo próximo a 1200 casos registrados em 2013 e um posterior decréscimo até atingir patamares inferiores a 500 registros em 2020.

O agregado das séries anteriores, obviamente apresenta uma evolução semelhante a séries anteriores, como é visível na Figura 4.1. As distinções surgem quando se avalia os índices proxy de crimes contra pessoas. No caso da evolução do indicador “homicídio doloso”, sendo uma série temporal com sazonalidade, a evolução de registros é marcada por movimentos cíclicos, mas a característica mais evidente de sua evolução é a tendência de queda registrada ao longo no período de 2012 a 2020.

Por fim, tem-se a evolução do indicador “latrocínio”, a qual se destoa da evolução dos casos anteriores. Tal indicador ao contrário dos casos anteriores, não apresenta uma tendência clara, tendo uma evolução semelhante à uma série caracterizada pelo chamado *random walk*.

Figura 4.1 - Séries escolhidas



Fonte: Elaboração própria

4.2 Identificação do processo e estimação do modelo.

A Metodologia Box-Jenkins possui como objetivo prever os valores de uma série temporal utilizando a correlação entre os valores realizados do processo estocástico. Ela se divide fundamentalmente em três estágios principais: (i) identificação do processo; (ii) estimação do modelo; (iii) diagnósticos dos resíduos. Concluído o último estágio, pode-se enfim realizar a previsão dos valores.

Na primeira etapa - identificação -, busca-se determinar os filtros (AR(p); I(d); MA(q); etc) que compõem o processo gerador da série e suas respectivas ordens (p, d, q). Este processo, geralmente, é baseado no comportamento das funções de autocorrelação (fac) e autocorrelação parcial (facp) empíricas, e com os resultados obtidos, tem início a etapa de estimação do modelo. Entretanto, afim de automatizar tanto a etapa de identificação do processo como a etapa de estimação do modelo, foi utilizado a função *auto.arima* do pacote *forecast* (HYNDAM et al., 2021) desenvolvido para o R, gerando por tal meio os modelos preliminares. Tal função usa uma variação do algoritmo Hyndman-Khandakar (Hyndman & Khandakar, 2008), que combina testes de raiz unitária, minimização do AIC e MLE para obter um modelo ARIMA, apresentando os valores no formato ARIMA(p, d, q). Pelo fato de as séries aqui utilizadas possuírem sazonalidade, além de retornar as ordens p, d e q, a função *auto.arima* retorna também as ordens P, D e Q, elementos que correspondem ao componente sazonal da auto-regressão (AR), da diferenciação (I) e da média móvel (MA), respectivamente. Assim os melhores modelos encontrados pela função *auto.arima* são apresentados no formato ARIMA(q, d, q)(P, D, Q).

Os argumentos da função *auto.arima* fornecem muitas variações no algoritmo, entretanto nesse trabalho é adotado o comportamento padrão da função. O algoritmo dessa função se inicia com dois processos principais: primeiro, a seleção dos parâmetros d e D e, segundo, a seleção da ordem do modelo. É importante que o algoritmo primeiro selecione os valores de D e d, uma vez que o valor do AIC, que é a medida de erro padrão do método, não é comparável para diferentes níveis de diferenciação. Assim, começar com a seleção de D e d evita problemas de compatibilidade entre as medições AIC feitas posteriormente. Uma vez selecionados os valores de d e D, o algoritmo procede à seleção de p, q, P e Q, também por meio da minimização do AIC.

Uma observação deve ser feita quanto à estimação de modelos para as séries temporais dos casos de “roubo de veículos” e “latrocínio”. Em tais séries, além da utilização da função *auto.arima* para uma estimativa inicial, foram necessários ajustes manuais nas ordens dos

modelos indicados pela função para se chegar aos melhores modelos preditivos possível. Tais ajustes foram feitos por meio da função Arima, também do pacote *forecast* (HYNDAM et al., 2021), que possibilita a realização dos ajustes manuais necessários.

Os melhores modelos encontrados são apresentados na Tabela 1:

Tabela 4.1 - Melhores modelos encontrados

Melhores modelos encontrados	
Indicador	Modelo
Furto de veículos	ARIMA(0,1,1)(2,0,0)
Roubo de veículos	ARIMA(2,1,2)(1,0,1)
Furto e roubo de veículos	ARIMA(0,1,1)(2,0,0)
Homicídio doloso	ARIMA(0,1,1)(0,0,2)
Latrocínio	ARIMA(1,1,2)(1,1,1)

Fonte: Elaboração própria

Além da estimação das ordens q , d , q , P , D e Q , a função *auto.arima* estima também os coeficientes dos modelos preditivo das séries utilizadas (ver Tabela 2).

Tabela 4.2 - Coeficientes dos melhores modelos encontrados

Coeficientes dos melhores modelos					
Coeficiente	Furto de veículos	Roubo de veículos	Furto e roubo de veículos	Homicídio doloso	Latrocínio
AR(1)	-	-0,7188	-	-	-0.8099
AR(2)	-	-0,1283	-	-	-
MA(1)	-0,4063	0,5306	-0,2515	-0,655	0,1911
MA(2)	-	-0,2598	-	-	-0.8089
SAR(1)	0,184	0,8779	0,2416	-	-0.2294
SAR(2)	0,4388	-	0,4153	-	-
SMA(1)	-	-0,6499	-	0,2204	-0.8822
SMA(2)	-	-	-	0,3857	-

Fonte: Elaboração própria

Com a estimação e determinação preliminar dos modelos, parte-se agora para a análise dos resíduos dos “melhores” modelos (terceira etapa), na qual temos três testes: teste de autocorrelação; teste de heterocedasticidade, e; teste de normalidade.

4.3 Diagnóstico dos resíduos

4.3.1 Teste de autocorrelação

Para a realização dos testes de autocorrelação foi utilizado a função *Box.test* do pacote *stats* (R CORE TEAM, 2021) nativo do R. Essa função calcula a estatística de teste Ljung-Box ou Box-Pierce para examinar a hipótese nula de independência em uma determinada série temporal. A função foi aplicada nas séries temporais dos cinco índices de criminalidades analisados, considerando seus respectivos *lags* e graus de liberdade (representados por “fitdf” na Tabela 3).

Como apresentado na Tabela 3, para o teste de autocorrelação do indicador “furto de veículos”, considerando 3 graus de liberdade, foram utilizados como *lags* os valores 4, 6 e 8. No caso do indicador “roubo de veículos”, foi considerado 6 graus de liberdade e aplicado os *lags* 8, 10 e 12. Quanto aos índices “furto e roubo de veículos” e “homicídio doloso”, considerou-se novamente 3 graus de liberdades e os *lags* 4, 6 e 8 para ambos. Por fim, tratando-se do indicador “latrocínio”, foi adotado 5 graus de liberdade e os *lag* 6, 8 e 10.

Entre os testes de autocorrelação realizados, apenas o melhor modelo preditivo encontrado para a série temporal “roubo de veículos” apresentou um p-valor inferior ao nível de significância de 5%, mais especificamente ao considerar um lag igual a 8 (ver Tabela 3). Nos demais casos, todos os p-valores encontrados por meio da função *Box.test* foram superiores ao nível de significância de 5%, indicando ser possível a rejeição da hipótese nula de que os resíduos dos melhores modelos encontrados são autocorrelacionados.

Tabela 4.3 - Teste de autocorrelação com o teste Ljung-Box

Teste de autocorrelação (p-valores do teste Ljung-Box)				
Furto de veículos	Roubo de veículos	Furto e roubo de veículos	Homicídio doloso	Latrocínio
0,424 (lag 4; fitdf 3)	0,02246 (lag 8; fitdf 6)	0,4249 (lag 4; fitdf 3)	0,1225 (lag 4; fitdf 3)	0,3221 (lag 6; fitdf 5)
0,7784 (lag 6; fitdf 3)	0,05748 (lag 10; fitdf 6)	0,6479 (lag 6; fitdf 3)	0,3604 (lag 6; fitdf 3)	0,3485 (lag 8; fitdf 5)
0,328 (lag 8; fitdf 3)	0,1095 (lag 12; fitdf 6)	0,3312 (lag 8; fitdf 3)	0,4797 (lag 8; fitdf 3)	0,5968 (lag 10; fitdf 5)

Fonte: Elaboração própria

4.3.2 Teste de heterocedasticidade

Para a realização do teste de heterocedasticidade, foi aplicada a função *Arch.test* do pacote *FinTS* (SPENCER GRAVES, 2019) do R. Essa função executa os testes Portmanteau Q e Multiplicador de Lagrange para contribuir com a avaliação da hipótese nula de que os resíduos de um modelo ARIMA são homocedásticos ou não. Com a realização dos testes de heterocedasticidade, foram obtidos p-valores superiores ao nível de significância de 5% na análise dos resíduos dos modelos preditivos de todos dos índices de criminalidade. Com tais resultados é possível não rejeitar a hipótese nula de que não há efeitos Arch, apontando assim para a ausência de heterocedasticidade e à indicação de que o processo é homocedástico. Tem-se, a partir disso, que os resíduos são homocedásticos e, portanto, são aceitos para a continuidade da análise dos modelos.

Tabela 4.4 - Teste de heterocedasticidade com o teste ARCH-LM

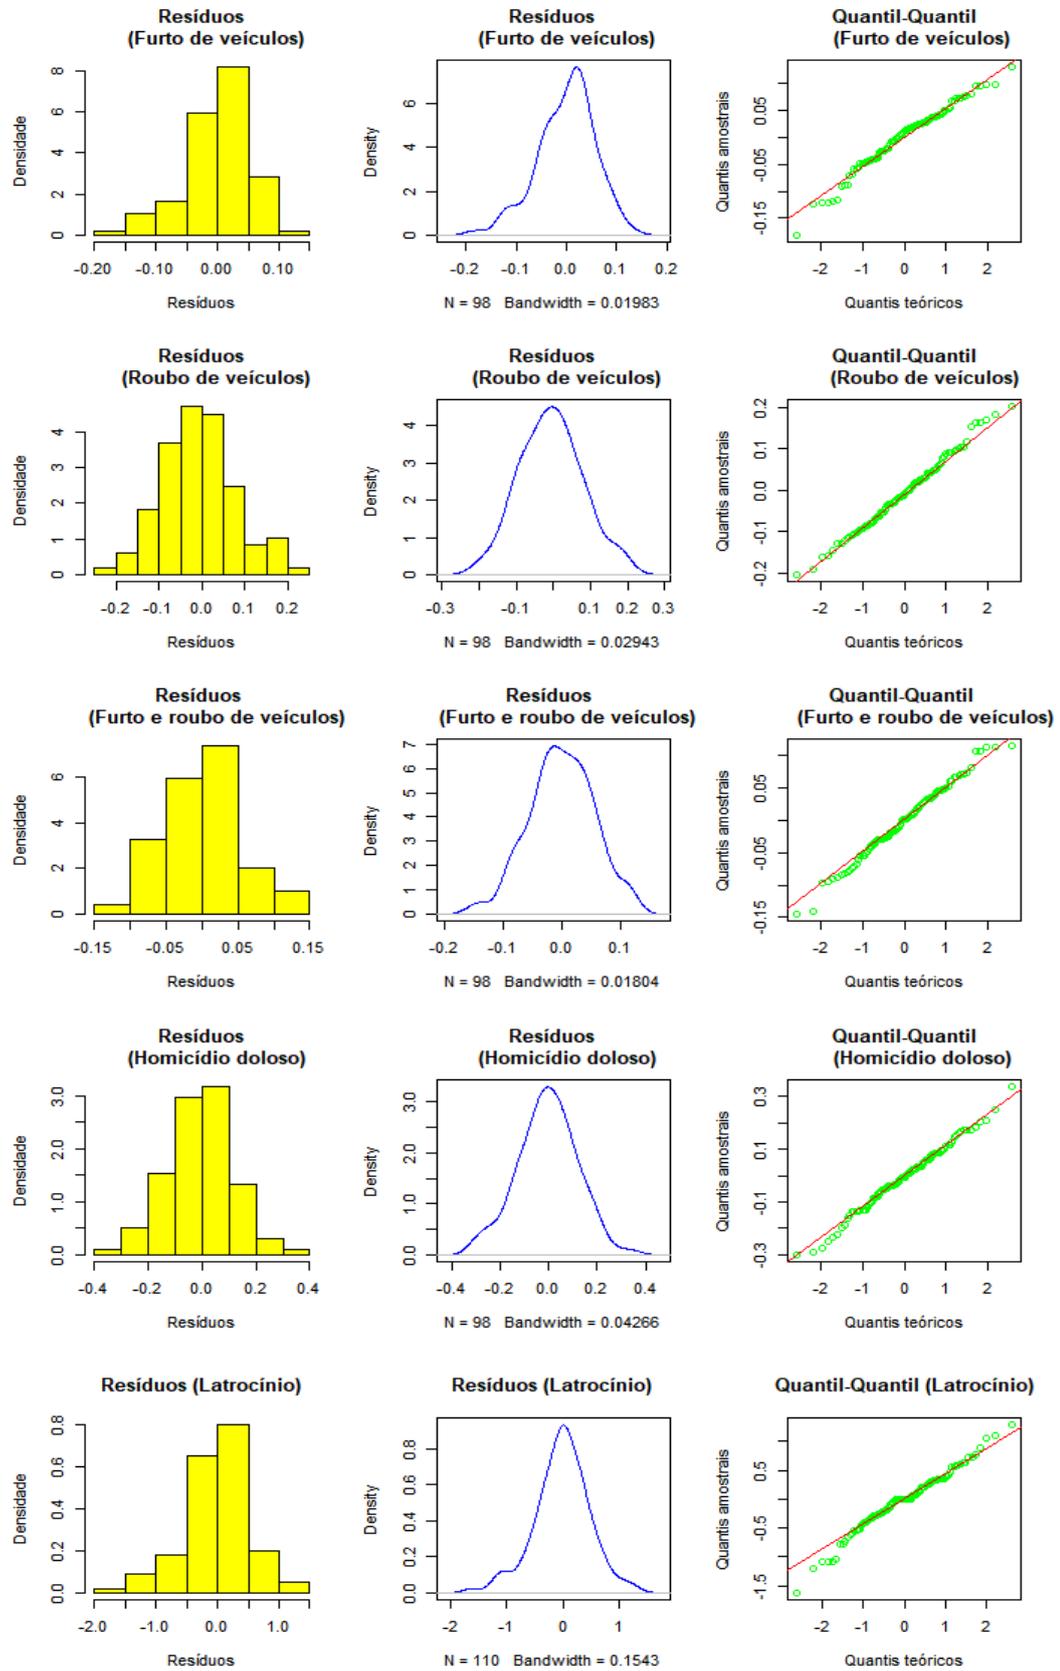
Teste de heterocedasticidade	
Indicadores	ARCH-LM (p-valor)
Furto de veículos	0,9045
Roubo de veículos	0,1709
Furto e roubo de veículos	0,6185
Homicídio doloso	0,4559
Latrocínio	0,5099

Fonte: Elaboração própria

4.3.3 Teste de normalidade

Partindo para o teste de normalidade, o primeiro passo a ser tomado é a análise visual da distribuição dos resíduos dos modelos preditivos dos cinco índices de criminalidades aqui estudados. Como apresentado pela Figura 4.2, os resíduos de todos os melhores modelos encontrados apresentam distribuição próximas a uma distribuição normal.

Figura 4.2 - Análise de resíduos



Fonte: Elaboração própria

É possível confirmar os resultados da análise visual por meio da aplicação de teste empírico utilizando a função *shapiro.test* do pacote *stats* (R CORE TEAM, 2021) nativo do R, a qual executa o teste de normalidade Shapiro-Wilk. Como é possível ser observado na Tabela 5, todos os p-valores resultantes do teste são superiores ao nível de significância de 5%, o que leva à não rejeição da hipótese nula de que os resíduos dos modelos encontrados possuem distribuição normal, confirmando assim os resultados da análise visual. Portanto, torna-se perceptível a presença de resíduos branco gaussiano nos modelos testados, caracterizando-os como bons modelos de previsão.

Tabela 4.5 - Teste de normalidade com o teste Shapiro-Wilk

Teste de normalidade	
Indicadores	Shapiro-Wilk (p-valor)
Furto de veículos	0,07823
Roubo de veículos	0,8847
Furto e roubo de veículos	0,6782
Homicídio doloso	0,9119
Latrocinio	0,3171

Fonte: Elaboração própria

4.4 Previsões das séries temporais

Concluídas as etapas de identificação dos processos, estimação dos modelos e diagnósticos dos resíduos e verificado que os melhores modelos preditivos encontrados de fato são adequados para a realização de previsões, chega-se no momento de utilizá-los de fato para a realização da previsão das séries temporais dos cinco índices de criminalidade estudados nesse trabalho. Nessa etapa, a fim de realizar as previsões, foi feito uso da função *forecast* do pacote de mesmo nome (HYNDAM et al., 2021). Essa função é uma função genérica para previsão de séries temporais ou modelos de séries temporais e invoca métodos específicos que dependem da classe do primeiro argumento.

Para as previsões, foi considerado doze passos à frente ($h=12$), ou seja, foi feita a previsão dos próximos doze meses posteriores ao mês de fevereiro de 2020 (março de 2020 a fevereiro de 2021). Os resultados obtidos podem ser observados na Tabela 6, mais especificamente nas colunas *Point Forecast*.

Tabela 4.6 - Resultado das previsões e valores observados

Furto de veículos - Previsão (h = 12)				
Mês	Point Forecast	Lo 95	Hi 95	Valor observado
mar/20	1390	1242	1555	1256
abr/20	1338	1173	1525	1024
mai/20	1265	1092	1465	928
jun/20	1315	1118	1545	899
jul/20	1346	1130	1603	878
ago/20	1334	1106	1609	790
set/20	1296	1063	1582	880
out/20	1351	1095	1667	914
nov/20	1375	1103	1713	853
dez/20	1284	1020	1616	905
jan/21	1277	1005	1623	969
fev/21	1249	974	1602	911

Roubo de veículos - Previsão (h = 12)				
Mês	Point Forecast	Lo 95	Hi 95	Valor observado
mar/20	491	414	583	489
abr/20	474	380	592	433
mai/20	489	384	623	342
jun/20	460	350	606	327
jul/20	470	349	632	309
ago/20	458	333	631	321
set/20	448	319	630	328
out/20	474	330	680	342
nov/20	451	308	659	330
dez/20	420	282	626	298
jan/21	432	285	654	340
fev/21	443	287	681	352

Furto e roubo de veículos - Previsão (h = 12)				
Mês	Point Forecast	Lo 95	Hi 95	Valor observado
mar/20	1881	1687	2097	1745
abr/20	1816	1585	2080	1457
mai/20	1753	1496	2054	1270
jun/20	1780	1490	2128	1226
jul/20	1819	1495	2212	1187
ago/20	1776	1437	2196	1111
set/20	1724	1373	2163	1208
out/20	1815	1425	2310	1256
nov/20	1804	1399	2328	1183
dez/20	1684	1289	2200	1203
jan/21	1690	1278	2235	1309
fev/21	1664	1244	2227	1263

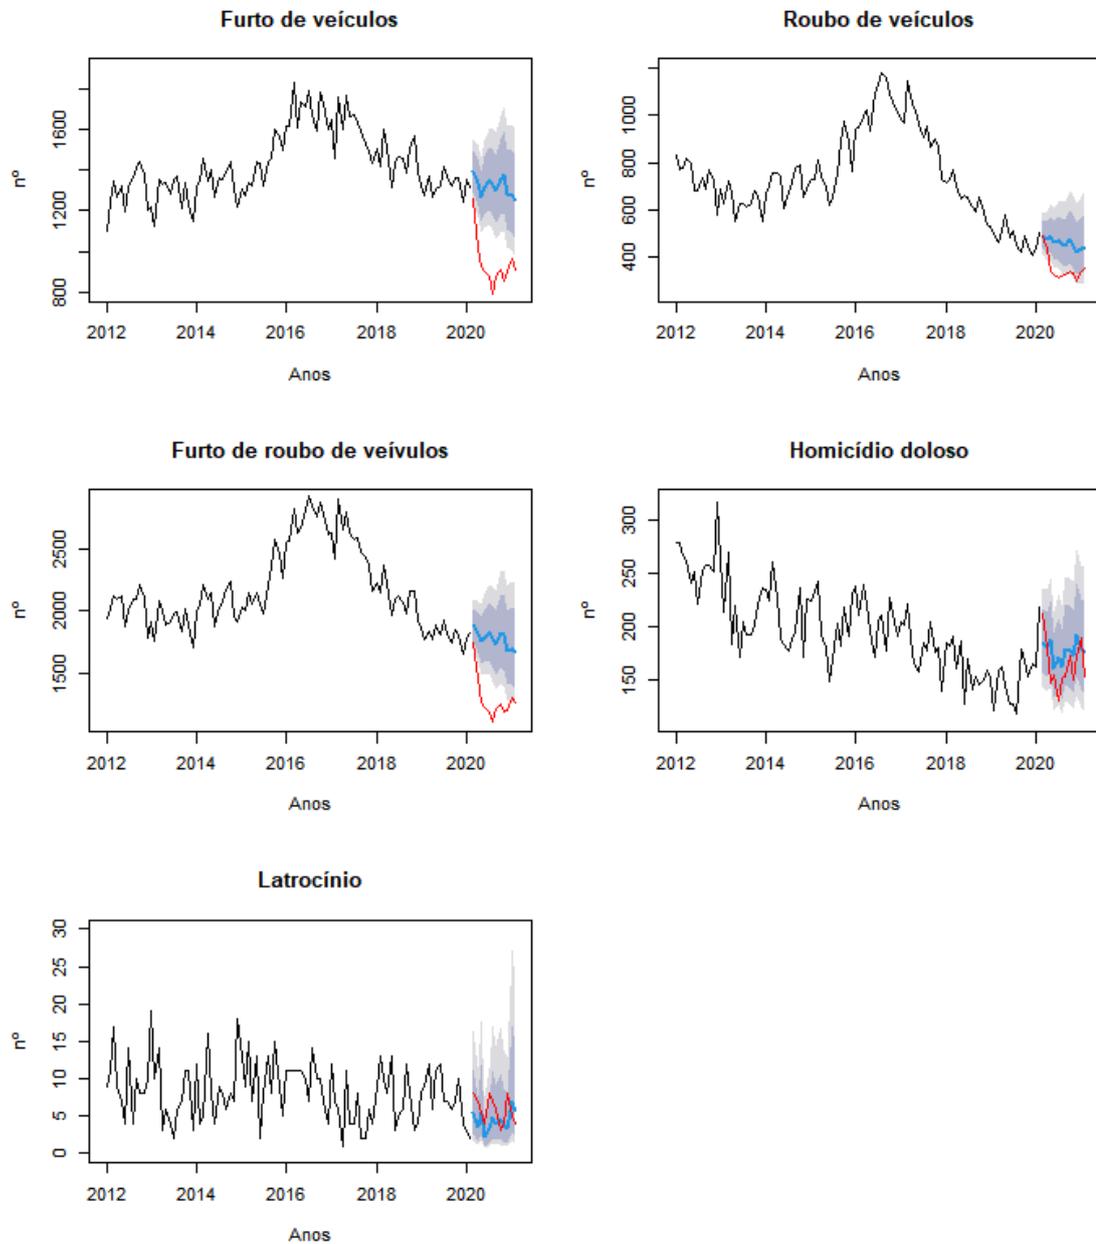
Homicídio doloso - Previsão (h = 12)				
Mês	Point Forecast	Lo 95	Hi 95	Valor observado
mar/20	184	145	235	212
abr/20	181	140	234	180
mai/20	187	143	246	148
jun/20	161	121	214	155
jul/20	171	127	230	130
ago/20	162	119	220	152
set/20	180	131	247	153
out/20	177	127	246	173
nov/20	173	123	242	151
dez/20	192	135	272	173
jan/21	179	125	256	189
fev/21	177	122	256	154

Latrocínio - Previsão (h = 12)				
Mês	Point Forecast	Lo 95	Hi 95	Valor observado
mar/20	7	3	22	8
abr/20	4	1	12	7
mai/20	7	2	22	6
jun/20	3	1	10	4
jul/20	4	1	13	8
ago/20	5	2	18	7
set/20	5	1	15	6
out/20	5	2	17	3
nov/20	5	1	16	4
dez/20	4	1	12	8
jan/21	6	2	21	5
fev/21	5	1	17	4

Fonte: Elaboração própria

Plotando em gráficos os valores da Tabela 4.6, é possível visualizar na Figura 4.3 os valores previstos e compará-los com os valores realmente observados no período escolhido para a realização das previsões. Na Figura 4.3, as linhas em preto correspondem as séries temporais utilizadas para a elaboração dos modelos preditivos. As linhas em azul, por sua vez, representam os resultados das previsões dos modelos elaborados. Quanto as linhas em vermelho, essas correspondem aos valores realmente observados dentro do intervalo de tempo delimitado para a realização das previsões.

Figura 4.3 – Plotagem dos resultados das previsões e dos valores observados



Fonte: Elaboração própria

Entre os cinco modelos preditivos desenvolvidos é perceptível que os modelos encontrados para os índices de crimes contra o patrimônio ("furto de veículos", "roubo de veículos" e "furto e roubo de veículos") foram os menos assertivos. Para esses índices, enquanto as previsões apontam para a continuidade de movimentos semelhantes ao registrados anteriormente, com uma tendência regular de queda, os valores realmente observados no mesmo recorte temporal das previsões mostram uma abrupta redução do registro de novos casos de furtos e roubos de veículos. Tratando-se dos índices de crimes contra pessoas ("homicídio

doloso” e “latrocínio”), é perceptível maior proximidade entre os valores previstos e os valores observados entre março de 2020 e fevereiro de 2021. Tal resultado indica que, entre os modelos apresentados, os modelos preditivos encontrados para os índices de homicídio doloso e latrocínio foram os mais assertivos na realização das previsões. Analisando o grau de assertividade dos modelos preditivos, e considerando que as divergências existentes entre valores previstos e observados se deve em grande parte a impactos causados pela pandemia, é possível também afirmar que a pandemia do covid-19 impactou de maneira diferente a ocorrência de registros de crimes, afetando com mais intensidade crimes contra o patrimônio (os quais apresentaram abrupta redução no início da pandemia) quando comparados à crimes contra pessoas.

Apesar das diferenças entre os resultados previstos e os resultados observados nas séries históricas, tais diferenças contribuem para a elaboração de estratégias de combate à criminalidade, principalmente em cenários nos quais são impostas situações semelhantes às causadas pela pandemia. Com a redução de crimes contra o patrimônio e relativa estabilidade nos registros de crimes contra pessoas, é possível se pensar em estratégias que dediquem maior esforços ao combate a crimes como homicídios dolosos de latrocínios, tendo em vista que, frente às previsões aqui desenvolvidas e os índices utilizados, esses foram os índices de criminalidade que menos tiveram alterações em sua evolução durante a pandemia desencadeada pelo covid-19.

5 CONSIDERAÇÕES FINAIS

No início do trabalho contatou-se que ferramentas tratadas pela econometria também podem contribuir com a elaboração de estratégias de combate ao crime, como é o caso de ferramentas que propiciam a geração de modelos preditivos de índices de criminalidade. Essas ferramentas podem ser aliadas ao combate à criminalidade, uma vez que, sendo fornecidas previsões sobre comportamentos de índices de criminalidade, é possível a aplicação mais eficaz de recursos, realocando-os em áreas estratégicas, obtendo, assim, melhores resultados em ações que visam a redução da ocorrência de crimes.

Diante disso, esse trabalho teve como objetivo geral encontrar e analisar os melhores modelos preditivos gerados pela metodologia Box-Jenkins ao ser aplicada em séries temporais de índices de criminalidade do estado do Paraná. Constata-se que o objetivo geral foi atendido, pois foi efetivamente possível construir modelos de previsão por meio da metodologia Box-Jenkins para cinco índices de criminalidade, sendo três índices proxy de crimes contra o

patrimônio ("furto de veículos", "roubo de veículos" e "furto e roubo de veículos") e dois índices proxy de crimes contra pessoas ("homicídio doloso" e "latrocínio").

Tem-se como objetivos específicos primeiramente a revisão bibliográfica, a qual foi cumprida apresentando diferentes teorias das causas da criminalidade e expondo os principais argumentos teóricos, desde os elaborados por estudiosos das Ciências Sociais aos elaborados por estudiosos da Economia, expondo também os principais debates teóricos entre a economia e a criminalidade e pesquisas desenvolvidas mais recentemente na literatura brasileira e em estudos voltados especificamente ao estado do Paraná.

O segundo objetivo específico foi a apresentação da metodologia Box-Jenkins, a qual foi utilizada para a elaboração dos modelos preditivos. Esse objetivo foi alcançado por meio da utilização da exposição feita por Pankratz (2009) sobre a metodologia preditiva aqui utilizada.

Como terceiro objetivo específico, tem-se a aplicação da metodologia Box-Jenkins às séries históricas previamente coletadas de índices de criminalidade e a análise dos resultados obtidos com os modelos preditivos elaborados. Com a utilização de ferramentas disponibilizadas pela linguagem de programação R, foi possível aplicar de fato a metodologia Box-Jenkins às séries históricas dos índices de criminalidade escolhidos, bem como testar a confiabilidade dos modelos preditivos gerados.

A pesquisa partiu da hipótese de que, entre as metodologias de previsão de variáveis, a metodologia Box-Jenkins é uma das metodologias que pode contribuir com a elaboração de modelos preditivos de índices de criminalidade, colaborando assim com planejamentos estratégicos mais precisos e direcionamento mais eficiente de recursos na atuação contra a criminalidade. Durante a elaboração do trabalho foi verificado que a metodologia Box-Jenkins é uma alternativa possível para a realização de previsões de índices de criminalidade, com previsões assertivas para os índices proxy de crimes contra pessoas. Entretanto, devido a ocorrência da pandemia causada pelo covid-19, houveram impactos consideráveis sobre as variáveis utilizadas, o que levou a geração de discrepância entre os resultados previstos e os realmente observados dentro do recorte temporal de previsão. Contudo, apesar das divergências entre valores previstos e observados, as previsões puderam servir de parâmetro para se observar como os cinco índices aqui estudados de fato evoluíram ao longo do primeiro ano de pandemia.

A pesquisa se iniciou com o levantamento bibliográfico, sendo utilizados como fontes de informações livros e artigos científicos, não se restringindo a um período específico. Nessa etapa, os primeiros esforços foram dedicados à busca de obras de diferentes áreas do conhecimento a fim de expor as diferentes teorias da causa da criminalidade, apresentando também trabalhos que contribuem para o debate teórico da relação entre economia e

criminalidade. Em seguida, foi construída a base de dados utilizada nos modelos de previsão. Para a construção de tal base de dados, foram extraídas séries temporais de índices de criminalidade dos relatórios anuais disponibilizados pela Secretaria de Segurança Pública do estado do Paraná.

Após a coleta de dados, foi realizada a etapa de apresentação da metodologia Box-Jenkins e dos passos que a compõe, evidenciando suas vantagens e desvantagens na elaboração de modelos preditivos. Depois da apresentação, foi feita a aplicação da metodologia Box-Jenkins, com a qual foram construídos modelos preditivos para os cinco indicadores de criminalidade utilizados nesse trabalho, sendo eles: “furto de veículos”, “roubo de veículos”, “furto e roubo de veículos”, “homicídio doloso” e “latrocínio”. Com a elaboração e testes dos modelos preditivos, posteriormente foram apresentados os resultados das previsões juntamente com a análise dos resultados gerados.

Nesse trabalho a principal limitação na análise dos resultados foram os efeitos que a pandemia desencadeou sobre a evolução dos índices de criminalidade. O isolamento social e as demais restrições necessárias para o combate a disseminação do covid-19 geraram um cenário distinto dos observados em períodos anteriores nas séries temporais escolhidas. Assim, a fim de verificar com maior precisão as potencialidades da metodologia Box-Jenkins ao ser aplicadas em índices de criminalidade, a aplicação de tal metodologia utilizando séries temporais com dados de um período pós-pandemia pode ser um caminho a ser seguido em trabalhos futuros. Não se limitando a utilização de séries temporais de períodos diferentes, a fim de verificar em estudos futuros os resultados aqui apresentados, recomenda-se também que os procedimentos aqui utilizados sejam aplicados a outros estados que venham a disponibilizar dados úteis de índices de criminalidade.

REFERÊNCIAS

ALVES, L. G. A.; RIBEIRO, H. V.; RODRIGUES, F. A. Crime prediction through urban metrics and statistical learning. **Physica A: Statistical Mechanics and its Applications**, v.505, p.435-443, 2018.

ANDRADE, M. V. E.; LISBOA, M. B. “Desesperança de Vida: Homicídio em Minas Gerais, Rio de Janeiro e São Paulo – 1981 a 1997”, in: HENRIQUES, R. (org.). **Desigualdade e Pobreza no Brasil**. Rio de Janeiro, IPEA, 2000.

ARAÚJO, E. G.; PROVENZA, M. M.; COSTA, J. F. S. **Uso de modelos estatísticos e previsão da violência letal no estado do Rio de Janeiro**. In: XLI Encontro Nacional de Engenharia de Produção. Foz do Iguaçu, Paraná, outubro, 2021.

BECKER, G. S. Crime and Punishment: An Economic Approach. **Journal of Political Economy**, v. 76, n. 2, pp. 169–217. 1968.

BOX, G. E.; JENKINS, G. M. Time Series Analysis: Forecasting and Control, ed. 2, San Francisco: Holden-Day, 1976.

CARNEIRO, L. P. Violent crime in Latin America cities. **Research Report**, Washington D. C., World Bank, 2000.

CERQUEIRA, D.; LOBÃO, W. Determinantes da criminalidade: Arcabouços teóricos e resultados empíricos. **Dados – Revista de Ciências Sociais**, v. 47, n. 2, pp. 233–269, 2004.

CLOWARD, R. e OHLIN, L. “Differential opportunity structure”. In: WOLFGANG, M. e FERRACUTI, F. (org.). **The sociology of crime and delinquency**. John Wiley & Sons, New York, pp. 300-318, 1970.

DURKHEIM, E. **Da divisão do trabalho social**. Martins Fontes, São Paulo, 2. ed. 1999 (Texto originalmente publicado em 1893).

EHRlich, I. Participation in Illegitimate Activities: A Theoretical and Empirical Investigation. **Journal of Political Economy**, v. 81, pp. 521-565, 1973.

ENTORF, H.; SPENGLER, H. (2002). Socio-economic Causes, Interactions and Consequences of Crime. In ENTORF, H.; SPENGLER, H. **Crime in Europe**, Springer, Berlin, pp. 29-96, 2002.

FAJNZYLBER, P.; AARAUJO JUNIOR, A. F. Violência e criminalidade. In: LISBOA, M. B.; MENEZES FILHO, N. A. (ed.). **Microeconomia e Sociedade no Brasil**, pp. 333–394, Rio de Janeiro. 2001.

GARRIDO, Adriana Cristina Oliver. Fatores sociais de criminalidade. *Revista sistema penal & violência*, v. 4, [s./p.], 2016.

GAULEZ, M. P.; MACIEL, V. F. Determinantes da criminalidade no Estado de São Paulo: uma análise espacial de dados em cross-section. **Anais do XLIII Encontro Nacional de Economia**, v. 8, 2015.

GONÇALVES JÚNIOR, C. A.; SHIKIDA, P. F. A. Determinantes da Reincidência Penal no Estado do Paraná: uma análise empírica da economia do crime. **Economic Analysis of Law Review, Brasilia**, v. 4, n. 2, pp. 315-336, Jul-Dec, 2013.

GOTTFREDSON, M., HIRSHI, T. **A general theory of crime**, Stanford University Press, Stanford, 1990.

HYNDMAN, R. J.; ATHANASOPOULOS, G.; BERGMEIR, C.; CACERES, G.; CHHAY, L.; O'HORA-WILD, M.; PETROPOULOS, F.; RAZBASH, S.; WANG, E.; YASMEEN, F. Forecast: Forecasting functions for time series and linear models, 2021. R package version 8.15. Disponível em: <https://pkg.robjhyndman.com/forecast>.

HYNDMAN, R. J.; KHANDAKAR, Y. Automatic time series forecasting: The forecast package for R. **Journal of Statistical Software**, v. 27, n. 3, pp. 1–22, 2008.

JOÃO, P. A. Modelo **Preditivo da Criminalidade Georeferenciação ao Concelho de Lisboa**. Dissertação (Mestrado em Estatística e Gestão de Informação) - Universidade Nova de Lisboa, Lisboa, 2009

LUCAS, M. S; CUNHA, M. S; BONDEZAN, K. L. Determinantes socioeconômicos da criminalidade no estado do Paraná: Uma análise espacial. **Revista de Economia**, v. 41, n. 75, pp. 248-281, 2020.

MACHADO, H. **Manual de sociologia do crime**. Ed. Afrontamento, Porto, 2008

MELO, F. S. **Modelagem de série temporal de homicídios dolosos registrados em Cuiabá e Várzea Grande com variáveis mesoclimáticas pelo método de Box-Jenkins**. Dissertações do (Mestrado em Ciências Ambientais) – Universidade de Cuiabá, Cuiabá-MT, 2019.

MENDONÇA, M. J. C. Um Modelo de Criminalidade para o Caso Brasileiro. **IPEA**. Manuscrito, 2000.

MERTON, R. K. “Social structure and anomie”. In: MERTON, R. K. **Social theory and social structure**, Free Press, Glencoe, 1958.

MILLER, W. “The lower class culture as a generating milieu of gang delinquency”. In: WOLFGANG, M. e FERRACUTI, F. (org.). **The sociology of crime and delinquency**, John Wiley & Sons, New York, pp. 351-363, 1970.

MOREIRA, R. C.; FOCHEZATTO, A. Análise espacial da criminalidade no Estado da Bahia. **Revista de Desenvolvimento Econômico**, v. 3, n. 38, 2017.

OLIVEIRA, C. de. Análise espacial da criminalidade no Rio Grande do Sul. **Revista de Economia**, v. 34, n. 3, p. 35-60, 2008.

PANKRATZ, A. Forecasting with univariate Box-Jenkins models: Concepts and cases, vol. 224, John Wiley & Sons, 2009.

PLASSA, W.; PARRÉ, J. L. A Violência no Estado do Paraná: uma análise espacial das taxas de homicídios e de fatores socioeconômicos. **Economia e Desenvolvimento**, Santa Maria, v.31, n. 1, pp. 01-16, 2019.

PROCÓPIO, Diego Pierotti. Fatores associados à criminalidade violenta no Brasil. Dissertação (Mestrado em Economia) - Universidade Federal de Viçosa, Viçosa-MG, 2014.

R CORE TEAM. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria, 2021. Disponível em: <https://www.R-project.org/>.

SAMPSON, R. J. Collective Regulation of Adolescent Misbehaviour: Validation Results from Eighty Chicago Neighborhoods. **Journal of Adolescent Research**, v. 12, pp. 227-244, 1997.

SANTOS, M. J.; KASSOUF, A. L. Estudos econômicos da criminalidade no Brasil: evidências e controvérsias. **Revista Economia**, Brasília, v. 9, p. 343-372, 2008

SASS, K. S.; PORSSE, A. A.; DA SILVA, E. R. H. Determinantes das taxas de crimes no Paraná: uma abordagem espacial. **Revista Brasileira de Estudos Regionais e Urbanos**, v. 10, n. 1, p. 44-63, 2016.

SELLIN, T. Culture Conflict and Crime, **Social Science Research Council**, New York, 1938.

SPENCER GRAVES. FinTS: Companion to Tsay (2005) Analysis of Financial Time Series, 2019. R package version 0.4-6. Disponível em: <https://CRAN.R-project.org/package=FinTS>.

SUTHERLAND, E. H. "Development of the Theory". In: SCHUESSLER, K (ed.). **Edwin Sutherland on Analyzing Crime**, Chicago University Press, Chicago, pp. 30-41, 1973 (Texto originalmente publicado em 1942).

SHIKIDA, P. F. A., ARAUJO JUNIOR, A. F., SHIKIDA, C. D., & BORILLI, S. P. Determinantes do comportamento criminoso: Um estudo econométrico nas penitenciárias central, estadual e feminina de Piraquara (Paraná). **Pesquisa e Debate**, v. 17, n. 1, pp. 125–148, 2006.

TEIXEIRA, J. M. Modelos de Previsão para índices criminais em três cidades do Sul de Minas Gerais. Dissertação (Mestrado em Agronomia/Estatística e Experimentação Agropecuária) - Universidade Federal de Lavras, Lavras-MG, 2006.