



MATHEUS DE ANDRADE FLAUSINO

**USO DE REDES COMPLEXAS PARA ANÁLISE DA RELAÇÃO
ENTRE A TOPOLOGIA URBANA DE CIDADES DE MINAS
GERAIS E A OCORRÊNCIA DE CRIMES DE RUA**

LAVRAS – MG

2024

MATHEUS DE ANDRADE FLAUSINO

**USO DE REDES COMPLEXAS PARA ANÁLISE DA RELAÇÃO ENTRE A
TOPOLOGIA URBANA DE CIDADES DE MINAS GERAIS E A OCORRÊNCIA DE
CRIMES DE RUA**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Ciência da Computação, área de concentração em Inteligência Artificial.

Prof. DSc. Eric Fernandes de Mello Araújo
Orientador

Prof. DSc. Angélica Sousa da Mata
Coorientadora

**LAVRAS – MG
2024**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a)**

Flausino, Matheus de Andrade

Uso de redes complexas para análise da relação entre a topologia urbana de cidades de Minas Gerais e a ocorrência de crimes de rua / Matheus de Andrade Flausino - 2024.

146 p.

Orientador(a): Eric Fernandes de Mello Araújo.

Coorientador(a): Angélica Sousa da Mata.

Dissertação (mestrado acadêmico) –Universidade Federal de Lavras, 2024.

Bibliografia.

1. redes complexas. 2.análise espacial. 3.crimes urbanos. I. Araújo, Eric Fernandes de Mello. II. da Mata, Angélica Sousa III. Título.

MATHEUS DE ANDRADE FLAUSINO

**USO DE REDES COMPLEXAS PARA ANÁLISE DA RELAÇÃO ENTRE A
TOPOLOGIA URBANA DE CIDADES DE MINAS GERAIS E A OCORRÊNCIA DE
CRIMES DE RUA**

**THE USE OF COMPLEX NETWORKS FOR ANALYZING THE RELATIONSHIP
BETWEEN THE URBAN TOPOLOGY OF CITIES IN MINAS GERAIS AND THE
OCCURRENCE OF STREET CRIMES**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Ciência da Computação, área de concentração em Inteligência Artificial.

APROVADA em 29 de Julho de 2024.

DSc. Gabriel Gomides Piva
Prof. DSc. Mayron César de Oliveira Moreira UFLA

Prof. DSc. Eric Fernandes de Mello Araújo
Orientador

Prof. DSc. Angélica Sousa da Mata
Co-Orientadora

**LAVRAS – MG
2024**

Aos meus pais, Vanderlei e Alessandra, cuja determinação e amor incondicional foram a base sólida sobre a qual construí meus sonhos e conquistei minhas metas. Enfrentaram enormes dificuldades para estudar e ofereceram, à mim e aos meus irmãos, um exemplo incomparável de perseverança e dedicação. Cada palavra de apoio e cada gesto de compreensão foram fundamentais para que eu pudesse superar os desafios e buscar o melhor de mim mesmo. Aos meus irmãos, Patrick, Fernanda, Mariah e Yuri que são uma fonte constante de alegria e inspiração. Que o futuro de cada um de vocês seja tão brilhante quanto a luz que vocês trazem para a minha vida, e que continuem a trilhar caminhos de sucesso e realização. À memória do meu querido tio Alexandre, cuja paixão pela educação e dedicação como profissional sempre foram uma fonte de inspiração e orientação. Seu compromisso com o saber e seu exemplo de vida me mostraram o verdadeiro valor do estudo e me orientaram em cada passo dessa jornada. Com gratidão e carinho, dedico este trabalho a vocês, que foram fundamentais para minha trajetória acadêmica e pessoal.

AGRADECIMENTOS

Gostaria de expressar minha mais profunda gratidão a todas as pessoas que contribuíram para a realização deste trabalho e para minha jornada acadêmica.

Primeiramente, agradeço ao meu orientador, professor Eric, pelo conhecimento valioso e suporte constante. Suas sugestões e críticas construtivas foram essenciais para o desenvolvimento e aprimoramento desta dissertação.

Minha sincera gratidão à minha coorientadora, professora Angélica, pela colaboração incansável e pelo apoio ao longo de todo o processo. Sua expertise e disponibilidade foram cruciais para a realização deste trabalho.

Agradeço também a todos os professores que tive o privilégio de ter durante o curso, cujas aulas e orientações foram fundamentais para a minha formação acadêmica e pessoal. Cada um de vocês contribuiu de forma significativa para meu crescimento e desenvolvimento.

Um agradecimento especial à minha amada Delane, cujo apoio incondicional e amoroso foi uma fonte constante de força e encorajamento. Sem você, muitos dos desafios teriam sido ainda mais difíceis de enfrentar, e sua presença foi um pilar fundamental em cada etapa desta jornada.

A todos vocês, meu sincero agradecimento por tornar possível a conclusão deste trabalho e por fazerem parte desta importante etapa da minha vida.

Aqueles que não se movem, não percebem suas correntes.
(Rosa Luxemburgo)

RESUMO

Os crimes representam desafios sociais complexos e existe uma vasta gama de estudos que propõem-se a explicá-los. Compreendê-los é uma etapa crucial para adoção de medidas efetivas no combate à criminalidade. Atualmente, os órgãos de segurança pública do Estado de Minas Gerais registram as informações espaço-temporais dos crimes, em específico os crimes de rua, em suas ocorrências, permitindo assim que tais episódios sejam analisados, inclusive considerando também a estrutura urbana de suas respectivas cidades. O objetivo deste trabalho foi caracterizar a estrutura urbana de cada cidade na forma de rede complexa e correlacionar tal estrutura com a localização da ocorrência desses crimes. As cidades envolvidas neste projeto são: Alfenas, Itabira, Itajubá, João Monlevade, Lavras, Ouro Preto, São João Del Rei e Viçosa, devido à facilidade de acesso aos dados destes municípios e a similaridade populacional destes municípios. Uma abordagem utilizando redes complexas e suas medidas de centralidade é utilizada para compreender a concentração espacial ao longo dos anos de ocorrência de crimes de rua praticados nas cidades envolvidas neste projeto durante o período entre os anos de 2014 e 2022. Os resultados mostram que a medida de centralidade por proximidade é a medida que apresenta melhores valores de correlação com as regiões de concentração criminal.

Palavras-chave: redes complexas; análise espacial; crimes urbanos; estruturas urbanas.

ABSTRACT

Crimes represent complex social challenges, and there is a wide range of studies aimed at explaining them. Understanding them is a crucial step for implementing effective measures to combat crime. Currently, public security agencies in the state of Minas Gerais record the spatiotemporal information of crimes, specifically street crimes, in their reports, which allows these incidents to be analyzed, including considering the urban structure of their respective cities. The aim of this study was to characterize the urban structure of each city as a complex network and correlate this structure with the location of these crimes. The cities involved in this project are: Alfenas, Itabira, Itajubá, João Monlevade, Lavras, Ouro Preto, São João Del Rei, and Viçosa, due to the ease of accessing data from these municipalities and their similar population sizes. An approach using complex networks and their centrality measures is employed to understand the spatial concentration of street crimes in these cities over the period from 2014 to 2022. The results show that the closeness centrality measure has the highest correlation with areas of criminal concentration.

Keywords: complex networks; spatial analysis; urban crimes; urban structures.

INDICADORES DE IMPACTO

O presente estudo, que aplica redes complexas como metodologia para a compreensão da criminalidade, tem um impacto potencial significativo nas estratégias de segurança pública, permitindo que as instituições se tornem mais eficientes na prevenção e combate aos crimes. Ao analisar as interações espaciais e sociais entre diferentes fatores que contribuem para a ocorrência de delitos, essa abordagem oferece insights valiosos sobre padrões e tendências que podem não ser evidentes em análises tradicionais. Isso possibilita a identificação de áreas críticas e a priorização de recursos de maneira mais inteligente e direcionada. Com uma compreensão mais profunda das dinâmicas criminosas, as autoridades podem desenvolver intervenções mais eficazes, adaptadas às especificidades de cada comunidade, promovendo não apenas a segurança, mas também o respeito aos direitos humanos. Assim, essa metodologia não apenas melhora a eficácia das ações institucionais, mas também contribui para um ambiente urbano mais seguro e justo para todos os cidadãos. Os dados utilizados neste trabalho são reais e fornecidos pela Polícia Militar de Minas Gerais, garantindo a relevância e a precisão das análises realizadas.

IMPACT INDICATORS

The present study, which applies complex networks as a methodology for understanding criminality, has significant potential impact on public safety strategies, allowing institutions to become more efficient in the prevention and combating of crimes. By analyzing the spatial and social interactions among different factors that contribute to the occurrence of offenses, this approach offers valuable insights into patterns and trends that may not be evident in traditional analyses. This enables the identification of critical areas and the prioritization of resources in a more intelligent and targeted manner. With a deeper understanding of criminal dynamics, authorities can develop more effective interventions tailored to the specificities of each community, promoting not only safety but also respect for human rights. Thus, this methodology not only enhances the effectiveness of institutional actions but also contributes to a safer and fairer urban environment for all citizens. The data used in this work are real and provided by the Military Police of Minas Gerais, ensuring the relevance and accuracy of the analyses conducted.

LISTA DE FIGURAS

Figura 2.1 – Representação das 7 pontes de Königsberg.	19
Figura 2.2 – Grafo criado a partir das 7 pontes de Königsberg.	20
Figura 2.3 – Representação gráfica de um grafo.	21
Figura 2.4 – Correlações de Pearson e Spearman.	29
Figura 4.1 – Trecho de código <i>Python</i> para extração da rede viária de São João Del Rei .	36
Figura 4.2 – Código <i>Python</i> para cálculo das medidas de centralidade de São João Del Rei.	38
Figura 4.3 – Código <i>Python</i> representando o cálculo de ocorrência da primeira estratégia.	40
Figura 4.4 – Código <i>Python</i> representando o cálculo de ocorrência da segunda estratégia.	41
Figura 4.5 – Código <i>Python</i> representando o cálculo de ocorrência da terceira estratégia.	43
Figura 5.1 – Mapa de calor das ocorrências do município de Alfenas.	47
Figura 5.2 – Mapa de calor das ocorrências do município de Itabira.	48
Figura 5.3 – Mapa de calor das ocorrências do município de Itajubá.	49
Figura 5.4 – Mapa de calor das ocorrências do município de João Monlevade.	49
Figura 5.5 – Mapa de calor das ocorrências do município de Lavras.	50
Figura 5.6 – Mapa de calor das ocorrências do município de Ouro Preto.	50
Figura 5.7 – Mapa de calor das ocorrências do município de São João Del Rei.	51
Figura 5.8 – Mapa de calor das ocorrências do município de Viçosa.	52
Figura 1 – Ilustração do grafo da primeira estratégia para a cidade de Alfenas.	67
Figura 2 – Ilustração do grafo da segunda estratégia para a cidade de Alfenas.	68
Figura 3 – Ilustração do grafo da terceira estratégia para a cidade de Alfenas.	69
Figura 4 – Ilustração do grafo de centralidade de grau para a cidade de Alfenas.	70
Figura 5 – Ilustração do grafo de centralidade de proximidade para a cidade de Alfenas.	71
Figura 6 – Ilustração do grafo de centralidade de intermediação para a cidade de Alfenas.	72
Figura 7 – Ilustração do grafo de centralidade de autovetor para a cidade de Alfenas. .	73
Figura 8 – Ilustração do grafo de centralidade Page Rank para a cidade de Alfenas. . .	74
Figura 9 – Ilustração do grafo para a medida de distância Universidade na cidade de Alfenas.	75
Figura 10 – Ilustração do grafo da primeira estratégia para a cidade de Itabira.	76
Figura 11 – Ilustração do grafo da segunda estratégia para a cidade de Itabira.	77
Figura 12 – Ilustração do grafo da terceira estratégia para a cidade de Itabira.	78

Figura 13 – Ilustração do grafo de centralidade de grau para a cidade de Itabira.	79
Figura 14 – Ilustração do grafo de centralidade de proximidade para a cidade de Itabira.	80
Figura 15 – Ilustração do grafo de centralidade de intermediação para a cidade de Itabira.	81
Figura 16 – Ilustração do grafo de centralidade de autovetor para a cidade de Itabira.	82
Figura 17 – Ilustração do grafo de centralidade Page Rank para a cidade de Itabira.	83
Figura 18 – Ilustração do grafo para a medida de distância universidade na cidade de Itabira.	84
Figura 19 – Ilustração do grafo da primeira estratégia para a cidade de Itajubá.	85
Figura 20 – Ilustração do grafo da segunda estratégia para a cidade de Itajubá.	86
Figura 21 – Ilustração do grafo da terceira estratégia para a cidade de Itajubá.	87
Figura 22 – Ilustração do grafo de centralidade de grau para a cidade de Itajubá.	88
Figura 23 – Ilustração do grafo de centralidade de proximidade para a cidade de Itajubá.	89
Figura 24 – Ilustração do grafo de centralidade de intermediação para a cidade de Itajubá.	90
Figura 25 – Ilustração do grafo de centralidade de autovetor para a cidade de Itajubá.	91
Figura 26 – Ilustração do grafo de centralidade Page Rank para a cidade de Itajubá.	92
Figura 27 – Ilustração do grafo para a medida de distância universidade na cidade de Itajubá.	93
Figura 28 – Ilustração do grafo da primeira estratégia para a cidade de João Monlevade.	94
Figura 29 – Ilustração do grafo da segunda estratégia para a cidade de João Monlevade.	95
Figura 30 – Ilustração do grafo da terceira estratégia para a cidade de João Monlevade.	96
Figura 31 – Ilustração do grafo de centralidade de grau para a cidade de João Monlevade.	97
Figura 32 – Ilustração do grafo de centralidade de proximidade para a cidade de João Monlevade.	98
Figura 33 – Ilustração do grafo de centralidade de intermediação para a cidade de João Monlevade.	99
Figura 34 – Ilustração do grafo de centralidade de autovetor para a cidade de João Monlevade.	100
Figura 35 – Ilustração do grafo de centralidade Page Rank para a cidade de João Monlevade.	101
Figura 36 – Ilustração do grafo para a medida de distância universidade na cidade de João Monlevade.	102
Figura 37 – Ilustração do grafo da primeira estratégia para a cidade de Lavras.	103

Figura 38 – Ilustração do grafo da segunda estratégia para a cidade de Lavras.	104
Figura 39 – Ilustração do grafo da terceira estratégia para a cidade de Lavras.	105
Figura 40 – Ilustração do grafo de centralidade de grau para a cidade de Lavras.	106
Figura 41 – Ilustração do grafo de centralidade de proximidade para a cidade de Lavras.	107
Figura 42 – Ilustração do grafo de centralidade de intermediação para a cidade de Lavras.	108
Figura 43 – Ilustração do grafo de centralidade de autovetor para a cidade de Lavras. . .	109
Figura 44 – Ilustração do grafo de centralidade Page Rank para a cidade de Lavras. . .	110
Figura 45 – Ilustração do grafo para a medida de distância universidade na cidade de Lavras.	111
Figura 46 – Ilustração do grafo da primeira estratégia para a cidade de Ouro Preto. . . .	112
Figura 47 – Ilustração do grafo da segunda estratégia para a cidade de Ouro Preto. . . .	113
Figura 48 – Ilustração do grafo da terceira estratégia para a cidade de Ouro Preto. . . .	114
Figura 49 – Ilustração do grafo de centralidade de grau para a cidade de Ouro Preto. . .	115
Figura 50 – Ilustração do grafo de centralidade de proximidade para a cidade de Ouro Preto.	116
Figura 51 – Ilustração do grafo de centralidade de intermediação para a cidade de Ouro Preto.	117
Figura 52 – Ilustração do grafo de centralidade de autovetor para a cidade de Ouro Preto.	118
Figura 53 – Ilustração do grafo de centralidade Page Rank para a cidade de Ouro Preto.	119
Figura 54 – Ilustração do grafo para a medida de distância universidade na cidade de Ouro Preto.	120
Figura 55 – Ilustração do grafo da primeira estratégia para a cidade de São João Del Rei.	121
Figura 56 – Ilustração do grafo da segunda estratégia para a cidade de São João Del Rei.	122
Figura 57 – Ilustração do grafo da terceira estratégia para a cidade de São João Del Rei.	123
Figura 58 – Ilustração do grafo de centralidade de grau para a cidade de São João Del Rei.	124
Figura 59 – Ilustração do grafo de centralidade de proximidade para a cidade de São João Del Rei.	125
Figura 60 – Ilustração do grafo de centralidade de intermediação para a cidade de São João Del Rei.	126
Figura 61 – Ilustração do grafo de centralidade de autovetor para a cidade de São João Del Rei.	127

Figura 62 – Ilustração do grafo de centralidade Page Rank para a cidade de São João Del Rei.	128
Figura 63 – Ilustração do grafo para a medida de distância universidade na cidade de São João Del Rei.	129
Figura 64 – Ilustração do grafo da primeira estratégia para a cidade de Viçosa.	130
Figura 65 – Ilustração do grafo da segunda estratégia para a cidade de Viçosa.	131
Figura 66 – Ilustração do grafo da terceira estratégia para a cidade de Viçosa.	132
Figura 67 – Ilustração do grafo de centralidade de grau para a cidade de Viçosa.	133
Figura 68 – Ilustração do grafo de centralidade de proximidade para a cidade de Viçosa.	134
Figura 69 – Ilustração do grafo de centralidade de intermediação para a cidade de Viçosa.	135
Figura 70 – Ilustração do grafo de centralidade de autovetor para a cidade de Viçosa.	136
Figura 71 – Ilustração do grafo de centralidade Page Rank para a cidade de Viçosa.	137
Figura 72 – Ilustração do grafo para a medida de distância universidade na cidade de Viçosa.	138
Figura 73 – Imagem de satélite retiradas do Google Earth destacando a localização da Universidade Federal de Alfenas.	139
Figura 74 – Imagem de satélite retiradas do Google Earth destacando a localização da Universidade Federal de Itajubá - Campus Itabira.	140
Figura 75 – Imagem de satélite retiradas do Google Earth destacando a localização da Universidade Federal de Itajubá.	141
Figura 76 – Imagem de satélite retiradas do Google Earth destacando a localização da Universidade Federal de Ouro Preto - Campus João Monlevade.	142
Figura 77 – Imagem de satélite retiradas do Google Earth destacando a localização da Universidade Federal de Lavras.	143
Figura 78 – Imagem de satélite retiradas do Google Earth destacando a localização da Universidade Federal de Ouro Preto.	144
Figura 79 – Imagem de satélite retiradas do Google Earth destacando a localização da Universidade Federal de São João del Rei.	145
Figura 80 – Imagem de satélite retiradas do Google Earth destacando a localização da Universidade Federal de Viçosa.	146

LISTA DE TABELAS

Tabela 2.1 – Tabela com interpretação convencional para os valores de correlação.	27
Tabela 4.1 – Dados do IBGE para os anos de 2022 a 2023.	33
Tabela 4.2 – Relação dos registros de ocorrências com coordenadas inválidas.	34
Tabela 4.3 – Quantidade de registros de crimes de rua por cidade.	34
Tabela 4.4 – Os diferentes tipos de causa presumida das ocorrências de crime em todas as cidades.	35
Tabela 4.5 – Relação dos crimes com êxito vs sem êxito.	35
Tabela 4.6 – Tipos de delito e quantidade de ocorrência.	36
Tabela 4.7 – Tabela com os pontos centrais de cada município.	37
Tabela 5.1 – Resultado do cálculo de CVT e EOT para as cidades.	53
Tabela 5.2 – Coeficiente de correlação de Spearman para o município de Alfenas.	55
Tabela 5.3 – Coeficiente de correlação de Spearman para o município de Itabira.	56
Tabela 5.4 – Coeficiente de correlação de Spearman para o município de Itajubá.	56
Tabela 5.5 – Coeficiente de correlação de Spearman para o município de João Monlevade.	57
Tabela 5.6 – Coeficiente de correlação de Spearman para o município de Lavras.	57
Tabela 5.7 – Coeficiente de correlação de Spearman para o município de Ouro Preto.	58
Tabela 5.8 – Coeficiente de correlação de Spearman para o município de São João Del Rei.	58
Tabela 5.9 – Coeficiente de correlação de Spearman para o município de Viçosa.	59

SUMÁRIO

1	INTRODUÇÃO	16
2	REFERENCIAL TEÓRICO	18
2.1	CRIMES URBANOS	18
2.2	TOPOLOGIA DE REDES	19
2.3	GRAFOS	20
2.4	REDES COMPLEXAS	22
2.5	COEFICIENTES DE CORRELAÇÃO	25
3	TRABALHOS RELACIONADOS	30
4	METODOLOGIA	32
4.1	DESCRIÇÃO DOS DADOS	33
4.2	MÉTODO	34
4.3	CÁLCULO DAS OCORRÊNCIAS	39
4.4	CORRELAÇÕES	43
4.5	FERRAMENTAS	44
5	RESULTADOS	46
5.1	GRAFOS DE OCORRÊNCIA E GRAFOS DE MEDIDAS	53
5.2	CORRELAÇÕES	54
6	DISCUSSÃO	60
	REFERÊNCIAS	64
	APENDICE A – GRAFOS	67
	APENDICE B – LOCALIZAÇÃO DAS UNIVERSIDADES	139

1 INTRODUÇÃO

O avanço do uso de tecnologias de geoprocessamento nos últimos anos tornou possível registrar informações mais precisas sobre a ocorrência dos crimes, e em particular, os crimes de rua. A expressão "Big Data" é tipicamente definida fazendo referência ao volume, variedade e velocidade dos dados que podem ser coletados, armazenados e analisados, mas também pela diversidade das tecnologias de captura de dados aplicadas a campos específicos para gerar novas perspectivas sobre comportamentos criminais e iniciar novas práticas de justiça criminal. Alguns criminologistas e agências de aplicação da lei buscam explorar essas capacidades para chegar a conclusões diagnósticas gerais ou específicas sobre as conexões entre crime e geografia, tendências criminais e traços/histórico pessoais, ou entre crimes passados e (previstos) futuros (SMITH; MOSES; CHAN, 2017).

A Criminologia já apresentou vários modelos, inclusive computacionais, para tentar explicar a ocorrência de crimes, e os fatores envolvidos neste fenômeno social. Estes modelos abrangem desde aspectos biológicos até elementos sociais, como é descrito, por exemplo, por GERRITSEN (2010), que formaliza e analisa diferentes teorias do espectro criminológico, e por BAAL (2004) que avalia a influência das sanções na dissuasão criminal.

Compreender padrões de crimes é um passo importante para a construção de políticas e estratégias de combate à criminalidade que sejam também efetivas. Considerando a quantidade de dados disponibilizados atualmente, e a modernização da polícia, é possível que haja avanços nos estudos criminológicos com respaldo em dados reais e que permitam um melhor ajuste dos modelos mais realistas. Além disso, os resultados deste tipo de trabalho podem ser utilizados de maneira ampla para apoio na tomada de decisões por parte dos órgãos de segurança pública, que sempre se encontra administrando recursos humanos e materiais limitados para o exercício de sua função.

Para tal, a proposta deste trabalho é implementar as redes complexas, que serão descritas na seção 2.4, alimentadas com os dados disponibilizados pela Polícia Militar de Minas Gerais (PM-MG) para avaliar os crimes de roubo de rua cometidos em cidades de Minas Gerais de médio porte e que contam com uma relevante presença de população universitária, devido à facilidade de acesso aos dados destes municípios e a similaridade populacional destes municípios. As representações construídas consideram que a estrutura urbana das cidades pode ser descrita na forma de grafos (redes complexas) e que as análises de métricas associadas aos dados ob-

tidos podem ajudar a compreender o padrão da localização de ocorrência dos delitos. Há uma expectativa dos autores deste estudo de que as características de redes complexas possam estar correlacionadas com o fenômeno da concentração espacial dos crimes apontado por ROSSER et al. (2017), tornando as características das redes urbanas uma importante variável tanto para criminologia quanto para modelos preditivos. Dessa forma, buscamos responder às seguintes perguntas:

- a) como representar a estrutura urbana em uma rede complexa e relacioná-la com a localização geográfica da ocorrência do crime?
- b) há relação entre a rede viária nas concentrações espaciais de ocorrência de crimes nas cidades estudadas?

O objetivo geral deste trabalho é, utilizando-se de redes complexas, investigar a influência das estruturas urbanas de cada uma das cidades envolvidas no projeto acerca da ocorrência dos crimes de rua. Espera-se que as análises sejam capazes de apresentar uma relação entre as regiões que ocorrem mais crimes nas cidades e sua estrutura urbana, permitindo ampliar a compreensão sobre os crimes em cidades de Minas Gerais.

Espera-se, ao fim do trabalho, contribuir para a área de Ciência da Computação por meio da criação de novas ferramentas computacionais úteis para a área de segurança urbana, bem como contribuir com ferramentas já existentes que permitam facilitar o trabalho nesta área de estudo. O estudo tem, dessa forma, natureza interdisciplinar e aplicada, sendo a nova metodologia a contribuição para a área de estudos.

O texto está dividido da seguinte maneira: No capítulo 2 são apresentadas as fundamentações teóricas deste trabalho que são importantes para a compreensão deste. No capítulo 3 são apresentados os trabalhos relacionados. No capítulo 4 são apresentados os métodos e os instrumentos adotados para dirigir a nossa investigação científica. No capítulo 5 são apresentados os resultados desta pesquisa. No capítulo 6 é apresentada a discussão dos resultados e as considerações finais.

2 REFERENCIAL TEÓRICO

Para compreender o fenômeno de crimes de rua em ambientes urbanos sob a metodologia (seção 4), é necessário introduzir aspectos da criminologia, dos grafos e redes complexas além das técnicas de correlação estatística.

2.1 CRIMES URBANOS

Entre os principais desafios que os aglomerados urbanos enfrentam está, cada vez mais, a crescente busca pela segurança que os espaços proporcionam e possam oferecer em relação ao crime. De acordo com COZENS (2011), se os cidadãos se sentem seguros, eles se tornam mais propensos a utilizar os espaços, contribuindo para a vitalidade e a sustentabilidade da cidade e do ambiente construído.

Existem vários estudos que examinam a relação entre o comportamento criminoso e as características do espaço urbano, utilizando um conjunto de teorias, abordagens, metodologias e seções temáticas (SOARES; SABOYA, 2019). Estudos apontam que o comportamento delinquente é muito influenciado pelos locais percorridos no cotidiano dos criminosos (ANDERSON; HUGHES, 2009; FELSON; GOTTFREDSON, 1984; WARR, 2005). Nesse contexto, as amenidades urbanas são importantes, pois a distribuição do uso e ocupação do solo no espaço urbano determinam áreas com concentração de público, realização de atividades com circulação monetária, entre outras coisas, o que aumenta a possibilidade de cometimento de atividades criminosas (FARIA; DINIZ; ALVES, 2020). As instalações (*facilities*) funcionam como “atrações” para o crime (*crime attractors*) (BRANTINGHAM; BRANTINGHAM, 1995).


Um crime pode ser definido como um fato, entendendo-se por tal não só a expressão da vontade mediante ação (voluntário movimento corpóreo) ou omissão (voluntária abstenção de movimento corpóreo), como também o resultado (*effectus sceleris*), isto é, a consequente lesão ou periclitación de um bem ou interesse jurídico penalmente tutelado (ELEUTÉRIO, 2005). Mais especificamente, este trabalho considera como objeto de estudo apenas os crimes de rua, também conhecidos na literatura como crimes do colarinho azul ou *blue-collars* e, apesar de não existir um termo padrão para definí-los podem ser entendidos como roubo ou furto, combinados ou não (TILLEY, 2004). Os tipos específicos de crimes de rua estudados aqui serão descritos no capítulo 4, na tabela 4.6.

2.2 TOPOLOGIA DE REDES

A topologia é uma área da matemática que estuda a maneira como os pontos de um conjunto estão distribuídos e conectados (ou não) entre si. Neste contexto, não é levada em consideração a forma exata dos objetos, mas sim, as propriedades que são preservadas quando, por exemplo, estes objetos são deformados (TOKORO; COSTA, 2021). É uma especialização relacionada com as propriedades e características que os corpos geométricos possuem e que permanecem inalteradas através de constantes mudanças, independentemente do seu tamanho ou aparência.


De acordo com ARAUJO et al. (2015), para entender a topologia de redes, é preciso voltar no século XVIII ao matemático Leonhard Euler e uma questão de planejamento urbano, mais conhecido como, o problema das pontes de Königsberg (Figura 2.1), na Prússia (atual Kaliningrado, Rússia). Na cidade, cortada pelo rio Nagel, formada por duas margens e duas ilhas centrais ligadas por sete pontes, seria possível percorrer as quatro áreas, partindo de qualquer ponto, atravessando todas as pontes uma única vez sem repeti-las?

Figura 2.1 – Representação das 7 pontes de Königsberg.



Fonte: DANTAS (2010)

Figura 2.2 – Grafo criado a partir das 7 pontes de Königsberg.



Fonte: AUTOR (2024)


Para resolver o problema, Euler transformou os caminhos em retas e as intersecções em pontos, criando assim, possivelmente, o primeiro grafo. O autor NETTO (1996) destacou o caráter icônico do grafo, dizendo que “a representação esquemática de grafos apresenta a vantagem da fácil apreensão pela percepção global no que se refere a alguns de seus aspectos topológicos”, ou seja, o grafo tem a capacidade de permitir uma extração direta dos dados do objeto pelo observador através de sua leitura simultânea. As representações dadas por meio de grafos são regidas apenas por relações topológicas entre os pontos que compõem sua forma espacial (ARAUJO et al., 2015).

2.3 GRAFOS

Formalmente, um **grafo** é um par (V, E) onde V é um conjunto arbitrário e E é um subconjunto de V de cardinalidade igual a 2. Assim, cada elemento de E terá a forma $\{u, v\}$ ou simplesmente uv . Os elementos de V são chamados de vértices e os elementos de E são chamados de arestas (no caso de grafos ponderados, apresentados na subseção 2.3.2, os elementos desse conjunto são mais conhecidos como arcos).

Se uma aresta $e = uv$ pertence ao grafo G então dizemos que ela **incide** nos vértices u e v , e que u e v são vizinhos ou adjacentes. Denota-se o conjunto de todos os vértices de um grafo G como sendo $V(G)$ e o conjunto de todas as arestas como sendo $E(G)$. A cardinalidade desses conjuntos podem ser escritos da seguinte forma $|V(G)|$ e $|E(G)|$ ou, simplesmente, $v(G)$ e $e(G)$. A ordem de um grafo G é a quantidade de vértices de G . Um grafo geralmente é representado graficamente por um conjunto de pontos simbolizando os vértices e um conjunto de linhas conectando pares de pontos simbolizando as arestas. A figura 2.3 apresenta duas representações gráficas de dois grafos distintos, onde ambos possuem seis vértices.

Figura 2.3 – Representação gráfica de um grafo.



Fonte: AUTOR (2024)

Arestas da forma $e = uu$, ou seja, cujos dois extremos são o mesmo vértice são conhecidas como **laço** e diferentes arestas que possuem os mesmos extremos são chamadas de **arestas múltiplas ou paralelas**. Grafos que não possuem nem arestas paralelas nem laços são chamados de **grafos simples**. Pode-se afirmar que, para grafos simples, a quantidade máxima de arestas é dada por $V^{(2)} = \binom{n}{2} = \frac{n(n-1)}{2}$, onde $V^{(2)}$ é o conjunto de pares não-ordenados de elementos de V e n é a quantidade de elementos de V ou, como definido anteriormente, $v(G)$ (FEOFILOFF; KOHAYAKAWA; WAKABAYASHI, 2011).

2.3.1 REPRESENTAÇÃO DOS GRAFOS

Os grafos podem ser representados de várias maneiras. Neste estudo, é apresentada especificamente a representação por matriz de adjacência, uma das formas clássicas de representação. A matriz de adjacência de um grafo é uma matriz onde tanto as colunas quanto as linhas são indexadas pelos vértices. Se $adj[u][v]$ representa um elemento nesta matriz, então temos que:

$$adj[u][v] \neq 0 \quad \text{se existe aresta entre } u \text{ e } v;$$

$$adj[u][v] = 0 \quad \text{se não existe aresta entre } u \text{ e } v.$$

2.3.2 GRAFOS DIRECIONADOS E PONDERADOS

É conhecido por grafo direcionado todas as redes onde as arestas entre dois vértices quaisquer u e v possuem uma direção particular, de u para v ou vice-versa. Dessa forma, diferente dos grafos não direcionados, a representação de um grafo direcionado pode não ser uma matriz simétrica, enquanto um grafo não direcionado sempre produzirá uma matriz simétrica.

Os grafos podem também possuir valores ou pesos associados a cada uma de suas arestas. Esses pesos têm por objetivo representar grandezas como custo, velocidade, tempo, largura de banda e etc. Esses grafos são conhecidos como grafos ponderados (BURGUILLO, 2018).

2.3.3 INCIDÊNCIAS

Pode-se extrair algumas informações do grafo ou vértices dado suas incidências. No caso de grafos simples, o **grau** de um vértice v de um grafo G , denotado por $d_G(v)$ é medido pela quantidade de vizinhos do vértice v . No caso do grafo já ter sido anteriormente explicitado, será utilizada a notação $d(v)$. Um vértice com $d(v) = 0$ é chamado de **vértice isolado**.

O grau mínimo de um grafo G , denotado por $\delta(G)$, é igual ao menor grau dentre todos os vértices do grafo:

$$\delta(G) = \min\{d(v) : v \in V(G)\}$$

Por outro lado, o grau máximo de G , denotado por $\Delta(G)$ é o maior grau dentre todos os vértices do grafo:

$$\Delta(G) = \max\{d(v) : v \in V(G)\}$$

E, por fim, o grau médio de G , denotado por $\bar{d}(G)$ é a média de todos os graus do grafo:

$$\bar{d}(G) = \frac{\sum_{v \in V(G)} d(v)}{v(G)}$$

2.4 REDES COMPLEXAS

Rede complexa é um objeto de estudo que faz parte da **Teoria das Redes** que, por sua vez, é uma parte da teoria dos grafos e também da área da computação e ciência das redes, e busca estudar os grafos como representações tanto simétricas quanto assimétricas das relações de objetos discretos. Para a teoria das redes, os atributos individuais de cada objeto são menos relevantes que suas relações dentro da rede. Essa abordagem se mostrou muito útil para explicar muitos fenômenos do mundo real, isto porque muitos problemas repousam na estrutura de suas redes, como por exemplo, espalhamento de informação em redes sociais, estruturas e cadeias econômicas, telecomunicações, dentre outros (BURGUILLO, 2018).

Neste contexto, uma rede complexa é um grafo que apresenta características diferentes das que ocorrem em redes simples, mas que se mostram evidentes nos grafos que modelam sistemas reais. Esta área tem sido cada vez mais explorada, inspirando-se por estudos empíricos sobre redes nas mais diversas áreas do conhecimento (MATA, 2020). De fato, redes sociais, biológicas e tecnológicas possuem interessantes características topológicas, com padrões de conexão nem sempre regulares, porém nem sempre randômicas (BURGUILLO, 2018).

2.4.1 MÉTRICAS EM REDES COMPLEXAS

Existem muitas métricas pré-definidas utilizadas para caracterizar uma dada rede complexa. Elas ajudam a compreender e distinguir distintos tipos de redes ou topologias.

2.4.1.1 CENTRALIDADE DE GRAU

A centralidade de grau é uma das mais básicas medidas de centralidade baseada em vértice e tem por objetivo determinar os nós mais centrais de uma rede em relação ao grau dos vértices: quanto maior o grau de um dado vértice, mais central ele é na rede e, portanto, o nó mais central de uma rede é aquele com a maior quantidade de conexões (MATA, 2020).

Para que seja plausível comparar a centralidade de grau entre vértices de grafos com ordens diferentes existe uma variação desta medida conhecida como **centralidade de grau relativa**. Essa medida considera o grau relativo do vértice que pode ser definido como:

$$cg(v)_r = \frac{d(v)}{v(G) - 1}$$

É possível afirmar que o grau máximo de qualquer vértice de qualquer rede é igual a $v(G) - 1$ e, portanto, essa medida reflete a proporção do grau do vértice em relação à ordem do grafo, permitindo assim, comparações entre grafos de distintas ordens.

2.4.1.2 CENTRALIDADE DE AUTOVETOR

A medida de centralidade de autovetor é feita de acordo com o conceito de que conexões com nós altamente conectados na rede contribuem mais para a significância do vértice em questão (MATA, 2020).

Matematicamente, a centralidade de autovetor $ce(v)$ de um vértice v é proporcional a soma de centralidade de seus vizinhos:

$$ca(v) = \frac{1}{\lambda} \sum_{w=1}^n A_{vw} x_w$$

Em que A é a matriz de adjacência que representa a rede e x é um autovetor de A com o autovalor λ . Dessa forma podemos utilizar a notação matricial para descrever a equação $Ax = \lambda x$ referenciando-se a todos os nós da rede (BURGUILLO, 2018).

2.4.1.3 CENTRALIDADE POR PROXIMIDADE

Medida baseada no conceito de caminho mais curto, tem por objetivo determinar quão próximo um vértice está dos demais em uma dada rede (BURGUILLO, 2018). Se um dado vértice é o mais próximo a todos os outros elementos da rede, então ele tem potencial para espalhar informação de maneira rápida e eficiente (CENTENO et al., 2022).

Desta forma, a centralidade de proximidade pode ser definida como sendo o inverso da soma dos caminhos mais curtos de um vértice v aos demais vértices da rede. Se chamarmos de d_{vw} a distância do caminho mais curto do nó v ao nó w e se nós definirmos \bar{d}_v como a média das distâncias, então, temos que:

$$\bar{d}_v = \frac{1}{n} \sum_w d_{vw}$$

Logo, podemos definir a centralidade por proximidade $cp(v)$ de um vértice v como sendo:

$$cp(v) = \frac{n}{\sum_w d_{vw}}$$

Assim os valores de $cp(v)$ ficam muito pequenos para vértices piores conectados, enquanto vértices bem conectados possuem altos valores de $cp(v)$ (BURGUILLO, 2018).

2.4.1.4 CENTRALIDADE POR INTERMEDIACÃO

Esta medida utiliza a proporção de todos os caminhos mais curtos da rede que passam por um determinado vértice (CENTENO et al., 2022). Nós com altos valores de centralidade

de intermediação são bons nós para a conectividade da rede, e indicam que sua remoção pode comprometer o fluxo de informação (BURGUILLO, 2018).

Matematicamente, tem-se que:

$$ci(v) = \sum_{v \neq w \neq z} \frac{\theta_{wz}^v}{\theta_{wz}}$$

Em que θ_{wz} é o número total de caminhos mais curtos entre w e z e θ_{wz}^v é o número total destes caminhos mais curtos que passam por v (MATA, 2020).

2.4.1.5 PAGE RANK

PageRank é um dos mais utilizados algoritmos de ranqueamento de páginas Web no mundo. Ele mede a importância de uma página utilizando a estrutura de *hyperlinks* da Web. O algoritmo foi formulado pelos fundadores da Google, Larry Page e Sergey Brin como base para seu motor de buscas. A importância de qualquer página é dada pelo número de sites que fazem *link* à ela (BENINCASA et al., 2017).

Uma versão simplificada do PageRank pode ser definida como:

$$PR(v) = c \sum_{w \in B(v)} \frac{PR(w)}{N_w}$$

Em que v representa uma determinada página (ou mais abstratamente, vértice) a ser ranqueada. $B(v)$ é o conjunto de páginas (vértices) que apontam para v . $PR(v)$ e $PR(w)$ são a pontuação da página v e w , respectivamente. N_w representa o número de *links* que partem de w , enquanto c consiste de um fator utilizado para normalização (XING; GHORBANI, 2004).

2.5 COEFICIENTES DE CORRELAÇÃO

A palavra *correlação* vem do Latim e significa "associação", "conexão", "correspondência", "interdependência". O termo foi introduzido na ciência pela primeira vez pelo naturalista francês Georges Cuvier (1769-1832), uma das figuras mais proeminentes das ciências naturais no início do século XIX (SHEVLYAKOV; OJA, 2016).

Hoje, em um sentido mais amplo, *correlação* é a medida de associação entre duas variáveis. Dessa forma, quando falamos de dados correlacionados, estamos dizendo que mudanças

na magnitude de uma variável está associada com uma mudança na magnitude de outra variável, seja na mesma direção (correlação positiva), ou em direções oposta (correlação negativa) (SCHOBER; SCHWARTE, 2018).

Correlação, portanto, é uma medida de uma relação monótona entre duas variáveis. Uma relação monótona é quando essa relação é sempre crescente ou decrescente em seu domínio, ou seja, a medida que uma das variáveis aumenta a outra também sempre aumenta ou sempre diminui (SCHOBER; SCHWARTE, 2018).

2.5.1 COEFICIENTE DE CORRELAÇÃO DE PEARSON

Atribuído à Karl Pearson o desenvolvimento dessa estatística, o coeficiente de correlação de Pearson, também conhecido como coeficiente de correlação produto-momento, é uma medida de relação **linear** entre duas variáveis (BRITTO et al., 2009).

A relação linear é um tipo específico de relação monótona entre duas variáveis, onde um aumento ou decréscimo de uma unidade em uma variável gera um aumento ou decréscimo de uma unidade na outra variável.

O coeficiente de correlação de Pearson é a correlação mais utilizada em análise estatística. Sejam X e Y duas variáveis da qual queremos calcular a correlação de Pearson, a fórmula é dada a seguir:

$$r = \frac{1}{n-1} \sum \left(\frac{x_i - X}{S_x} \right) \left(\frac{y_i - Y}{S_y} \right)$$

Em que:

- a) n é o tamanho do conjunto das variáveis X e Y;
- b) x_i e y_i são, respectivamente, cada um dos elementos de X e Y;
- c) S_x e S_y são, respectivamente, os desvios padrões de X e Y;
- d) r é o coeficiente da correlação que varia entre -1 a +1.

2.5.1.1 INTERPRETAÇÃO DO COEFICIENTE DE CORRELAÇÃO

Muitas abordagens já foram apresentadas para *rotular* o coeficiente de correlação, encaixando a relação em rótulos como, por exemplo, "fraca", "forte" ou mesmo "moderada". Esses rótulos, no entanto, são arbitrários e devem ser utilizados com prudência. Muitos pesquisadores

concordariam facilmente que um coeficiente > 0.9 indica uma correlação forte, enquanto um coeficiente < 0.1 indica uma correlação fraca. No entanto, os valores dentro deste intervalo são discutíveis (SCHOBER; SCHWARTE, 2018).

A seguir uma estratificação convencional para interpretar o coeficiente de correlação.

Tabela 2.1 – Tabela com interpretação convencional para os valores de correlação.

Valor absoluto do coeficiente	Interpretação
0.0 - 0.1	Correlação desprezível
0.1 - 0.39	Correlação fraca
0.4 - 0.69	Correlação moderada
0.7 - 0.89	Correlação forte
0.9 - 1.0	Correlação muito forte

Fonte: SCHOBER; SCHWARTE (2018)

Porém, é muito recomendado que se avalie a força da relação entre duas variáveis à luz do contexto da questão científica posta.

2.5.1.2 PRESSUPOSTOS DA CORRELAÇÃO DE PEARSON

Assim como as interpretações, os pressupostos da correlação de Pearson tem sido bastante debatidos. Isso por que, de fato, o coeficiente de correlação pode até ser medido sem levar em conta nenhum pressuposto. Porém, uma boa avaliação da força da relação e da inferência desta para a população da qual a amostra foi coletada exigem alguns pressupostos (SCHOBER; SCHWARTE, 2018). A seguir listaremos essas premissas:

- a) em caso de inferência estatística, os dados da amostra devem ser aleatórios ou representativos da população de interesse. De outra forma, não são é possível extrair conclusões significativas sobre a população;
- b) ambas as variáveis devem ser contínuas e, em caso de amostragem, devem seguir uma distribuição normal bivariada da população a qual foram extraídas.

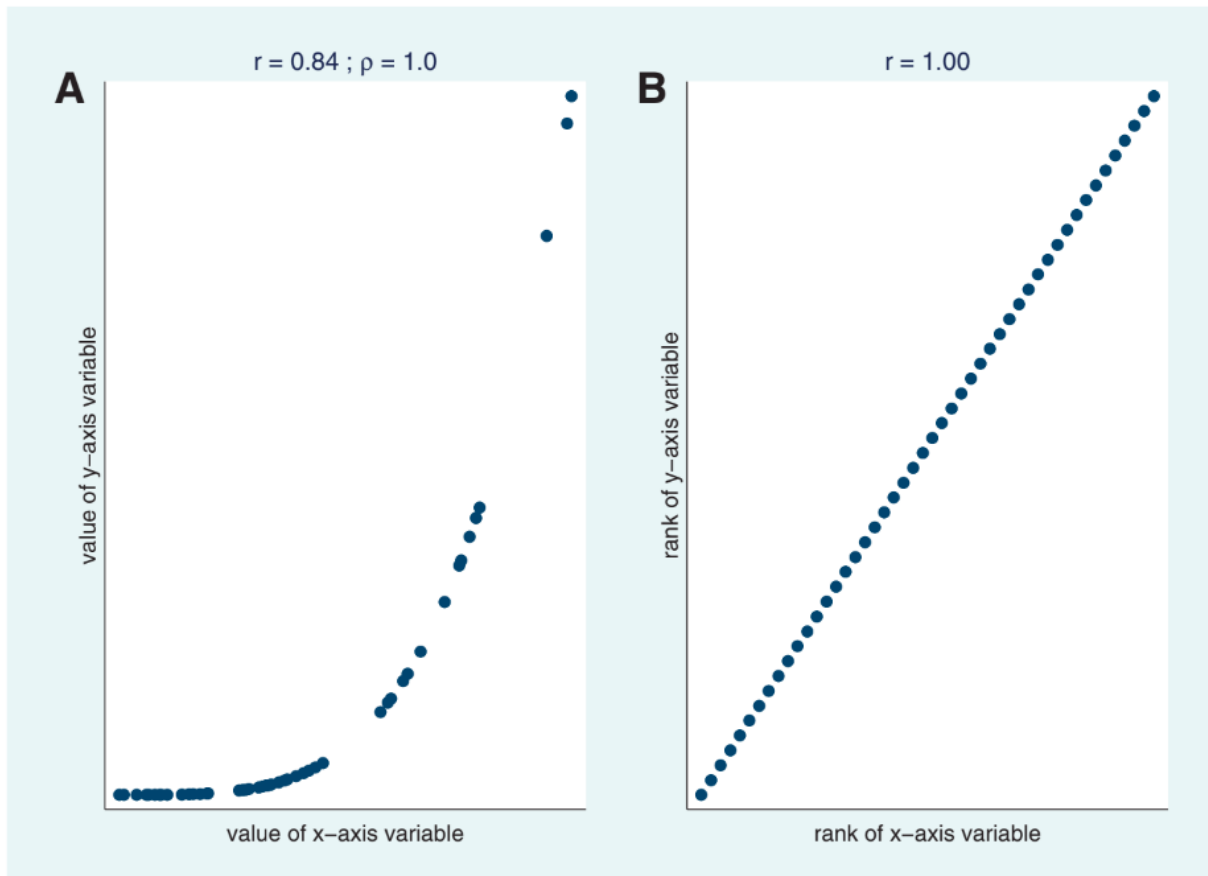
2.5.2 COEFICIENTE DE CORRELAÇÃO DE SPEARMAN

A correlação de Spearman nada mais é do que a correlação de Pearson calculada com os postos (*ranks*) dos valores de cada uma das variáveis ao invés do valor das variáveis em si. Essa forma de cálculo implica em algumas diferenças entre a correlação de Spearman e a correlação de Pearson.

Como valores ordinais também podem ser *ranqueados*, o uso da correlação de Spearman não fica limitado a variáveis contínuas. Além disso, por utilizar os postos dos valores, a correlação de Spearman é uma medida de relação monótona **não linear** entre duas variáveis (SCHOBER; SCHWARTE, 2018).

Na figura 2.4 observa-se em **A** uma curva monótona cujo coeficiente de correlação de Pearson é igual a 0.84 e de Spearman é igual a 1.0 (correlação perfeita). O cálculo dos postos destes valores pode ser visto em **B**, formando uma relação linear perfeita. Dessa forma, a correlação perfeita de Spearman ($\rho = 1.0$) em **A** corresponde a correlação perfeita de Pearson ($r = 1.0$) em **B**.

Figura 2.4 – Correlações de Pearson e Spearman.



Fonte: SCHOBER; SCHWARTE (2018)

Quanto a interpretação do coeficiente de correlação, se aplica à Spearman as mesmas observações feitas a Pearson na subseção 2.5.1.1.

3 TRABALHOS RELACIONADOS

Nesta seção, serão apresentados os trabalhos previamente realizados que se encontram diretamente relacionados ao escopo e objetivos desta pesquisa. A análise dos trabalhos anteriores é fundamental para contextualizar e fundamentar as abordagens e contribuições propostas neste estudo. Serão discutidos os principais estudos e avanços no campo, identificando lacunas no conhecimento existente e destacando as contribuições específicas que este trabalho oferece para a ampliação do entendimento e aprimoramento das práticas nesta área de estudo.

Em JIANG; CLARAMUNT (2004) a abstração da topologia urbana é transformada para uma outra chamada de *named-street*. Nesta visão, os nós representam ruas inteiras e as arestas as conexões que cada rua tem umas com as outras. Esta abordagem permite uma representação um tanto quanto adequada da conectividade das ruas. No entanto, ela perde o aspecto geográfico que é de extrema importância para o nosso trabalho. A proposta de JIANG; CLARAMUNT (2004), apesar de apresentar uma interessante visão para construção da representação da topologia urbana, não trata de relacionar sua morfologia com ocorrência de crimes.

O trabalho de MAO et al. (2021) conduziu uma revisão da literatura sobre o relacionamento entre o ambiente urbano e o crime, considerando o ambiente urbano em três níveis espaciais: as redes viárias, as ruas (caminhos) e os nós. Os nós aqui, se referem bastante a representação de instalações nas cidades, como por exemplo, paradas de ônibus, hotéis e etc. Dessa forma, essa revisão da literatura possui íntima relação com o trabalho aqui desenvolvido.

Segundo MAO et al. (2021) podemos dividir os elementos morfológicos incluídos nas pesquisas já existentes em dois grupos: geométricos e topológicos. O primeiro trata sobre características fáceis de se descrever da composição morfológica, como por exemplo, densidade, comprimento, largura e hierarquia, enquanto o último trata das características subjacentes da composição como por exemplo: permeabilidade, acessibilidade e conectividade. A presente pesquisa se encontra na categoria das que observam a influência dos elementos topológicos na ocorrência de crimes.

O trabalho de YUE et al. (2018) apresenta uma abordagem metodológica semelhante a nossa: utiliza o conceito de centralidade por intermediação (*betweenness*) como medida para a permeabilidade das ruas, medida esta que está prevista no nosso trabalho. No entanto, este conceito de permeabilidade foi aplicado apenas de maneira local, considerando 500m de raio para jornadas realizadas por pedestres e 5000m de raio para jornadas feitas por motoristas. Dessa

forma, a centralidade por intermediação não é considerada para todos os pontos do grafo apenas de um ponto i para outro ponto j dentro das áreas de raios anteriormente descritos. E, por fim, os autores juntam à permeabilidade calculada outras variáveis como por exemplo porcentagem de desempregados para calcular a relação com crimes através do método de regressão binomial.

A presente pesquisa distingui-se das demais encontradas na literatura por alguns aspectos que aqui serão descritos. Primeiramente, ela utiliza apenas registros de crimes que, apesar de apresentarem distinção entre si, como por exemplo, roubo de valores de transeunte e roubo de veículo ou embarcação, foram todos registrados como tendo sido executados na rua. Além disso, considera que a representação das vias urbanas das cidades na forma de redes complexas podem possuir características por si só que ajudam a compreender as ocorrências de crimes. Muitas pesquisas da literatura desenvolvem uma metodologia considerando as características topológicas das vias urbanas a partir de uma visão gerencial, como por exemplo, hierarquizar as ruas como sendo arteriais, coletoras e locais.

O quadro 3.1 apresenta as principais categorias morfológicas e suas características encontradas nas pesquisas.

Quadro 3.1 – Características morfológicas e seus principais parâmetros.

Categoria	Características	Método de caracterização
Geométrica	Densidade da rede viária	A proporção entre o comprimento total das ruas/estradas e a área total do terreno em um lote
	Comprimento	Comprimento dos segmentos de rua
	Hierarquia	Ruas arteriais principais, ruas arteriais secundárias, ruas coletoras e assim por diante
Topológica	Permeabilidade	Número de estradas ligadas diretamente às estradas principais (WHITE, 1990) <i>Betweenness</i> entre os segmentos de rua (YUE et al., 2018)
	Acessibilidade	O número de “curvas” em cada segmento de rua, fluxo de tráfego na rua (BEAVON; BRANTINGHAM; BRANTINGHAM, 1994)
	Conectividade	Número de cruzamentos (SOHN, 2016)

Fonte: MAO et al. (2021).

4 METODOLOGIA

Neste capítulo, são definidos os procedimentos técnicos a serem realizados a fim de garantir autenticidade, confiabilidade e valor científico para este estudo.

Esta pesquisa possui acesso aos dados sobre os crimes de ruas de oito cidades do interior de Minas Gerais, e são elas: Alfenas, Itabira, Itajubá, João Monlevade, Lavras, Ouro Preto, São João Del Rei e Viçosa. Esses dados foram fornecidos pela Polícia Militar do Estado de Minas Gerais (PMMG).

Essas cidades foram selecionadas por possuírem população semelhante e, por isso, permitir comparações de natureza científica entre elas. Os municípios são considerados similares por possuírem polos de universidades federais e contarem com uma relevante população universitária. Quantitativamente, essas cidades possuem entre 70 e 110 mil habitantes e todas são os municípios com maior população na sua região geográfica imediata. Todos estes municípios são do interior do Estado de Minas Gerais. A tabela 4.1, apresenta breves dados da pesquisa realizada pelo Instituto Brasileiro de Geografia e Estatística (IBGE) para as cidades em estudo (IBGE, 2020).

O tamanho populacional é, geralmente, a dimensão mais levada em consideração nas políticas públicas e nas ciências, havendo muito estudos que tentam definir o que são as pequenas, médias e grandes cidades (BITOUN, 2009). Existe um limiar, um tanto arbitrário, onde diversos estudos agrupam cidades com mais de 100 mil habitantes em um grupo diferente de cidades com menos de 100 mil habitantes. Nesse cenário, neste trabalho existem duas cidades que estariam em um grupo diferente das demais: Lavras e Itabira. No entanto, como o valor de 100 mil habitantes é arbitrário e essas cidades possuem a quantidade populacional muito próxima a 100 mil habitantes, consideraremos aqui que todas as cidades fazem parte do mesmo grupo populacional.

Os dados referentes a ocorrência de crimes de ruas são todos de um mesmo período histórico, referem-se ao intervalo que compreende os anos de 2014 a 2022 e vale para todos os municípios acima citados.

Tabela 4.1 – Dados do IBGE para os anos de 2022 a 2023.

Cidades	Área territorial	População	Densidade	PIB (R\$)
Alfenas	850,446 km ²	78.970	92,86 hab/km ²	33.843,71
Itabira	1.253,704 km ²	113.343	90,41 hab/km ²	56.164,20
Itajubá	294,835 km ²	93.073	315,68 hab/km ²	33.809,39
João Monlevade	99,158 km ²	80.187	808,68 hab/km ²	41.476,05
Lavras	564,744 km ²	104.761	185,50 hab/km ²	25.560,18
Ouro Preto	1.245,865 km ²	74.824	60,06 hab/km ²	50.312,19
São João Del Rei	1.452,002 km ²	90.225	62,14 hab/km ²	27.659,48
Viçosa	299,418 km ²	76.430	255,26 hab/km ²	22.472,92

Fonte: IBGE (2020)

4.1 DESCRIÇÃO DOS DADOS

A base de dados foi disponibilizada pela Polícia Militar de Minas Gerais e consiste de um arquivo Excel com os registros de crimes de rua. É importante ressaltar que apenas esse tipo de crime foi disponibilizado para este projeto. Cada linha do arquivo indica uma ocorrência e, inicialmente, existem 8364 registros de ocorrência destes crimes na base de dados. Para cada registro existem 35 campos (colunas) com informações relevantes e específicas à ocorrência.

De todos os campos que os registros da base possuem, dois precisam ser obrigatórios: **Longitude** e **Latitude**. Como o objetivo deste trabalho é avaliar e comparar a concentração geográfica da ocorrência de crimes com as características da estrutura das ruas das cidades analisadas, estas duas informações são imprescindíveis. Logo, todos os registros da base de dados que não possuem informação de Latitude ou Longitude foram descartados.

No total foram identificados 453 registros com coordenadas de latitude ou longitude inválidas dentro da base de dados, o que representa 5,42% do total de registros.

De fato, para execução da pesquisa é necessário apenas as informações de longitude, latitude e município de ocorrência. No entanto, podemos utilizar as demais informações dos registros para visualizar algumas características dos delitos. A tabela 4.3 apresenta os registros de ocorrência agrupados por cidade.

A tabela 4.4 apresenta as prováveis causas de cada ocorrência. É importante perceber que a vasta maioria das ocorrências aconteceu pelo ofensor ter encontrado uma oportunidade de obter vantagem econômica. Vale ressaltar que todas as ocorrências de qualquer que seja a causa presumida foi considerada na pesquisa.

Tabela 4.2 – Relação dos registros de ocorrências com coordenadas inválidas.

Município	Coords válidas	Coords inválidas	Total	% inválida
Alfenas	1692	73	1765	4,14%
Itabira	1419	46	1465	3,14%
Itajubá	729	36	765	4,71%
João Monlevade	1298	50	1348	3,71%
Lavras	566	26	592	4,39%
Ouro Preto	565	97	662	14,65%
São João Del Rei	303	62	365	16,99%
Viçosa	1339	63	1402	4,49%
Total	7911	453	8364	5,42%

Fonte: Autor (2024)

Tabela 4.3 – Quantidade de registros de crimes de rua por cidade.

Município	Quantidade Total	Porcentagem
Alfenas	1692	21,4%
Itabira	1 419	17,9%
Itajubá	729	9,2%
João Monlevade	1298	16,4%
Lavras	566	7,2%
Ouro Preto	565	7,1%
São João Del Rei	303	3,8%
Viçosa	1339	16,9%

Fonte: Autor (2024)

A tabela 4.5 apresenta a relação dos crimes tentados com êxito e tentados sem êxito em cada cidade.

A tabela 4.6 apresenta todos os possíveis tipos de delito presente na base de dados. Todos eles são subtipos dos crimes de furto ou roubo. Todos os tipos de delito apresentados foram considerados na pesquisa.

4.2 MÉTODO

Parte central do desenvolvimento da nossa pesquisa é ter disponível a representação da rede viária de cada um dos municípios. As redes viárias nada mais são do que as ruas, avenidas e rodovias que fazem parte de cada um dos municípios.

O projeto foi construído utilizando principalmente a linguagem de programação Python e suas bibliotecas. Para a criação do grafo de cada município foi coletada a informação geográ-

Tabela 4.4 – Os diferentes tipos de causa presumida das ocorrências de crime em todas as cidades.

Causa Presumida	Quantidade Total
Ação / Disputa de quadrilhas	1
Ação de gangues / facções criminosas	104
Autor com outras dívidas	10
Briga	1
Briga / Atrito	14
Embriaguez	5
Envolvimento com drogas	144
Ignorado	1597
Outras movimentações / causas	495
Preenchimento opcional	60
Vantagem econômica	5474
Vingança	6

Fonte: Autor (2024)

Tabela 4.5 – Relação dos crimes com êxito vs sem êxito.

Município	Quantidade com êxito	Quantidade sem êxito
Alfenas	1555	137
Itabira	1311	108
Itajubá	603	126
João Monlevade	1196	102
Lavras	478	88
Ouro Preto	503	62
São João Del Rei	243	60
Viçosa	1239	100

Fonte: Autor (2024)

fica das vias urbanas disponíveis na plataforma OpenStreetMap através da biblioteca OSMnx e já convertidas em grafos. A biblioteca OSMnx processa automaticamente a topologia crua dos dados do OpenStreetMap de forma com que as arestas dos grafos representem os segmentos de rua e os nós representem os cruzamentos entre os segmentos ou mesmo regiões sem saída. Um exemplo de código para extrair a rede viária de cada cidade é exibido na figura 4.1.

O método `graph_from_point` da biblioteca OSMnx será o responsável por devolver um grafo que represente a região informada nos parâmetros. Para definir a localidade de cada um dos municípios, utilizamos três parâmetros:

- a) **center point:** Ponto central em torno do qual o grafo será construído. É uma tupla com os valores de latitude e longitude;

Tabela 4.6 – Tipos de delito e quantidade de ocorrência.

Delito	Quantidade Total
Valores de transeunte	4397
Veículo ou embarcação	1222
Valores de motorista / passageiro de veículo particular	921
Valores de estabelecimento/pessoa jurídica	279
Valores de proprietário / funcionários de estabelecimento	245
Outros bens / valores de outro local	218
Valores de motorista / cobrador de transporte coletivo	157
Valores de morador de residência	143
Motorista de táxi	133
Valores em interior de veículo	58
Cargas	57
Valores de cliente de estabelecimento	39
Valores de passageiros de transporte coletivo	32
Valores de trabalhador de rua	9
Valores de morador de rua	1

Fonte: Autor (2024)

Figura 4.1 – Trecho de código *Python* para extração da rede viária de São João Del Rei

```

1 import osmnx as ox
2
3 G = ox.graph.graph_from_point((-21.123135, -44.245778), dist=5000,
4     network_type="drive")
5 ox.save_graphml(G, "saojoao.graphml")

```

Fonte: Autor (2024)

- b) **dist**: Tamanho do raio, em metros, a partir do ponto central que determinará toda a área que será construído o grafo. Ou seja, todos os elementos da rede viária que possuam uma distância para o ponto central menor que a distância (*dist*) informada farão parte da construção do grafo;

c) **network_type**: Tipo da rede viária que será considerada. No nosso caso, serão retornadas as vias públicas dirigíveis.

Para o parâmetro *dist* colocamos o valor de 5000 (em metros) para todos os municípios. Esse valor foi suficiente para cobrir satisfatoriamente as vias urbanas de todos municípios. Além disso, foi possível construir uma área onde a vasta maioria das ocorrências de cada município pudessem ser geograficamente abrangidas. A visualização e maiores detalhes sobre os grafos serão apresentados no capítulo 5 e no apêndice A.

O valor de *center point* foi obtido utilizando a ferramenta **Google Maps**. Para cada município, foi, arbitrariamente, selecionado um ponto mais central e coletado seus valores de latitude e longitude. O ponto central de cada uma das cidades pode ser visto na tabela 4.7:

Tabela 4.7 – Tabela com os pontos centrais de cada município.

Cidade	Latitude	Longitude
Alfenas	-21.420327	-45.948580
Itabira	-19.644693	-43.228580
Itajubá	-22.426959	-45.463703
João Monlevade	-19.820029	-43.154901
Lavras	-21.244698	-44.996468
Ouro Preto	-20.391875	-43.502574
São João Del Rei	-21.123135	-44.245778
Viçosa	-20.748481	-42.878345

Fonte: Autor (2024)

4.2.1 MEDIDAS E ESTRATÉGIAS

A partir dos grafos de cada um dos municípios, construiu-se dois tipos de grafos distintos: os grafos de **métricas** e os grafos de **ocorrências**. Chama-se de grafos de métricas, todos os grafos que representam alguma característica da rede de um determinado município. Foram utilizadas as seguintes características para cada município: centralidade de grau, centralidade de proximidade, centralidade de intermediação, centralidade de autovetor, Page Rank e distância para universidade. Logo, cada cidade possuía **seis** grafos de métricas.

Todas essas centralidades já foram apresentadas no capítulo 2, exceto a distância para a universidade que será abordada agora. Aproveitando a característica universitária dos municí-

pios desta pesquisa, foi adicionada a informação da distância para a universidade que consiste em calcular para cada vértice (cruzamento) do grafo a distância que ele se encontra da universidade da cidade. Apenas a sede ou polo principal da universidade federal do município foram consideradas. Os detalhes da construção desses grafos estão registrados na seção 4.2.2

Por outro lado, chama-se de grafos de ocorrências, todos os grafos que representam alguma estratégia para incorporar as ocorrências de crimes na rede de cada município. Três estratégias similares mas com algumas particularidades entre si foram utilizadas. Essas estratégias serão melhores descritas na seção 4.3. Cada município têm **três** grafos de ocorrências.

4.2.2 CÁLCULO DAS MEDIDAS DE CENTRALIDADE

Para calcular as diversas medidas de centralidade das redes de cada município, foi utilizada a biblioteca **networkx** (4.5.3). A biblioteca OSMnx (4.5.2), anteriormente mencionada para extrair a rede de cada cidade da plataforma OpenStreetMap, foi construída em cima da biblioteca **networkx**, e portanto, as redes obtidas já se encontram totalmente compatíveis com **networkx**, não sendo necessário nenhuma conversão ou configuração adicional.

O trecho de código que calcula as medidas de centralidade e incorpora estes valores de centralidade de cada nó ao grafo pode ser visto na figura 4.2.

Figura 4.2 – Código *Python* para cálculo das medidas de centralidade de São João Del Rei.

```

1 import networkx as nx
2
3 G = ox.load_graphml('saojoao.graphml')
4 D = ox.utils_graph.get_digraph(G)
5
6 bc = nx.betweenness_centrality(D)
7 cc = nx.closeness_centrality(D)
8 dc = nx.degree_centrality(D)
9 ec = nx.eigenvector_centrality(D, max_iter=600)
10 pc = nx.pagerank(D, max_iter=600)
11
12 nx.set_node_attributes(G, values=bc, name='betweenness')
13 nx.set_node_attributes(G, values=cc, name='closeness')
14 nx.set_node_attributes(G, values=dc, name='degree')
15 nx.set_node_attributes(G, values=ec, name='eigenvector')
16 nx.set_node_attributes(G, values=pc, name='page')

```

Fonte: Autor (2024)

As funções *eigenvector centrality* e *pagerank* exigem que o grafo seja um dígrafo, por isso há a conversão na linha 4 do trecho de código apresentado.

4.3 CÁLCULO DAS OCORRÊNCIAS

Anteriormente, mencionamos que há três estratégias distintas para incorporação das ocorrências às redes de cada cidade. Nesta seção daremos mais detalhes sobre todas estas estratégias.

Contudo, antes de iniciarmos a descrição de cada forma com que a ocorrência é associada ao grafo, nós iremos abordar a biblioteca *Haversine*. *Haversine* é um biblioteca que contém a implementação da fórmula *haversine* que, por sua vez, é uma fórmula que calcula a distância entre dois pontos distintos na Terra utilizando seus valores de latitude e longitude. Esta biblioteca é muito útil pois todas as formas de calcular as ocorrências dos grafos dependem do cálculo de distância entre dois pontos na Terra.

4.3.1 PRIMEIRA ESTRATÉGIA

O código *Python* que representa a primeira estratégia pode ser visto na figura 4.3

O objetivo desta primeira forma é associar uma ocorrência ao cruzamento (vértice) mais próximo. Desta maneira, temos:

- a) na linha 15 é iniciada uma iteração sobre a base de dados de ocorrências do município;
- b) na linha 16 a variável *dist* é iniciada com o maior valor de float possível;
- c) na linha 18 é extraída a informação geográfica da ocorrência na forma de tupla (ponto);
- d) na linha 20 é iniciada outra iteração mas agora sobre todos os vértices da rede;
- e) na linha 21 é extraída a informação geográfica do cruzamento (vértice) na forma de tupla (ponto);
- f) na linha 22 é calculada a distância entre os dois pontos;
- g) na linha 23 ocorre uma avaliação se essa distância é a menor calculada até então e, em caso positivo, ocorre o armazenamento do cruzamento para posteriormente, nas linhas 27 e 28, ser computado uma ocorrência a mais para este cruzamento;

Figura 4.3 – Código *Python* representando o cálculo de ocorrência da primeira estratégia.

```

1 import osmnx as ox
2 import networkx as nx
3 import pandas as pd
4 import haversine as hs
5
6 G = ox.load_graphml('saojoao.graphml')
7 G = nx.convert_node_labels_to_integers(G, first_label=0, ordering='
   default', label_attribute='old_index')
8
9 df = pd.read_csv('DadosRefinados-SAOJOAO.csv')
10
11 nr_nodes = nx.number_of_nodes(G)
12
13 ocorrencias = {i: 0 for i in range(nr_nodes)}
14
15 for index, row in df.iterrows():
16     max_dist = float('inf')
17     cruzamento_selecionado = None;
18     local_ocorrencia = (row['Latitude'], row['Longitude'])
19
20     for u, data in G.nodes(data=True):
21         local_cruzamento = (data['y'], data['x'])
22         dist = hs.haversine(local_ocorrencia, local_cruzamento, unit=
   hs.Unit.METERS)
23         if(dist < max_dist):
24             max_dist = dist
25             cruzamento_selecionado = u
26
27     if cruzamento_selecionado is not None:
28         ocorrencias[cruzamento_selecionado] += 1
29
30 nx.set_node_attributes(G, ocorrencias, name="nr_ocorrencias")

```

Fonte: Autor (2024)

h) por fim, na linha 30 é incorporado ao grafo a associação das ocorrências com o cruzamento mais próximo. A quantidade de ocorrência que cada vértice do grafo possui associada a si pode ser acessada através da propriedade *nr_ocorrencias*.

4.3.2 SEGUNDA ESTRATÉGIA

A figura 4.4 ilustra o código *Python* que representa a segunda forma:

Figura 4.4 – Código *Python* representando o cálculo de ocorrência da segunda estratégia.

```

1 ... #codigo anterior omitido
2
3 ocorrencias = {i: 0 for i in range(nr_nodes)}
4
5 for index, row in df.iterrows():
6     max_dist_1 = float('inf')
7     max_dist_2 = float('inf')
8     max_dist_3 = float('inf')
9     max_dist_4 = float('inf')
10
11     cruzamento_selecionado_1 = None;
12     cruzamento_selecionado_2 = None;
13     cruzamento_selecionado_3 = None;
14     cruzamento_selecionado_4 = None;
15     local_ocorrencia = (row['Latitude'], row['Longitude'])
16
17     for u, data in G.nodes(data=True):
18         local_cruzamento = (data['y'], data['x'])
19         dist = hs.haversine(local_ocorrencia, local_cruzamento, unit=
hs.Unit.METERS)
20
21         if(dist < max_dist_1):
22             max_dist_4 = max_dist_3
23             cruzamento_selecionado_4 = cruzamento_selecionado_3
24
25             max_dist_3 = max_dist_2
26             cruzamento_selecionado_3 = cruzamento_selecionado_2
27
28             max_dist_2 = max_dist_1
29             cruzamento_selecionado_2 = cruzamento_selecionado_1
30
31             max_dist_1 = dist
32             cruzamento_selecionado_1 = u
33
34         elif ... #ate cruzamento 4
35
36     if cruzamento_selecionado_1 is not None:
37         ocorrencias[cruzamento_selecionado_1] += 0.4
38
39     if cruzamento_selecionado_2 is not None:
40         ocorrencias[cruzamento_selecionado_2] += 0.3
41
42     if ... #ate cruzamento 4
43
44 dadoscalculados['quantidade_ocorrencia_2'] = ocorrencias.values()
45
46 ... # continua

```

Esta forma é muito similar a primeira com uma adição: contabilizar uma ocorrência não apenas para o primeiro cruzamento mais próximo mas sim para os quatro primeiros cruzamentos mais próximos. São dois os objetivos para esta estratégia. O primeiro consiste em não penalizar excessivamente os cruzamentos que também estão muito próximo à ocorrências, mas que não são necessariamente os primeiros e acabam, muitas vezes, não contabilizando uma única ocorrência sequer ao final da computação da **primeira forma**. Dessa forma, a associação da ocorrência aos cruzamentos (vértices) também é modificada. Cada cruzamento receberá uma fração da ocorrência inteira, sendo que o cruzamento mais próximo receberá 40% (0.4), o segundo 30% (0.3), o terceiro 20% (0.2) e o quarto 10% (0.1), totalizando 100% da ocorrência. Chamaremos essa associação de associação ponderada.

O segundo objetivo tem relação com a forma com que a associação das ocorrências e cruzamentos ocorrem nesta forma. Uma vez que os cruzamentos recebem frações do valor de uma ocorrência inteira as possibilidades estatísticas se ampliam, permitindo os cruzamentos possuírem mais valores distintos entre si.

O trecho de código desta forma é muito similar à primeira, mas podemos ressaltar o seguinte:

- a) o bloco que corresponde da linha 21 até a 34 é responsável por ordenar os cruzamentos mais próximos da ocorrência em avaliação;
- b) o bloco que corresponde da linha 36 até a 42 é responsável por fazer a associação ponderada nos cruzamentos mais próximos;
- c) na linha 44 é armazenado os valores calculados para a associação ponderada para futuras análises.

4.3.3 TERCEIRA ESTRATÉGIA

O trecho de código *Python* que representa a terceira forma pode ser visto na figura 4.5:

Por sua vez, a terceira e última forma é muito semelhante à segunda. Ela utiliza o mesmo mecanismo de ordenar os quatro cruzamentos mais próximos e, por isso, o trecho de código apresenta apenas a parte que difere esta forma da segunda: o cálculo de associação cruzamento ocorrência. O objetivo desta é, além dos já mencionados na segunda forma, transformar a associação ponderada em uma distribuição contínua. A fórmula que utilizamos para isso é uma proporção inversa, ou seja, quanto mais distante o cruzamento está da ocorrência menor é

Figura 4.5 – Código *Python* representando o cálculo de ocorrência da terceira estratégia.

```

1 ... #codigo anterior omitido
2
3     if cruzamento_selecionado_1 is not None:
4         ocorrencias[cruzamento_selecionado_1] += (1000/max_dist_1)
5
6     if cruzamento_selecionado_2 is not None:
7         ocorrencias[cruzamento_selecionado_2] += (1000/max_dist_2)
8
9     if cruzamento_selecionado_3 is not None:
10        ocorrencias[cruzamento_selecionado_3] += (1000/max_dist_3)
11
12    if cruzamento_selecionado_4 is not None:
13        ocorrencias[cruzamento_selecionado_4] += (1000/max_dist_4)
14
15 dadoscalculados['medida_influencia_crime'] = ocorrencias.values()
16 dadoscalculados.to_csv(caminho_medidas, index=False);

```

Fonte: Autor (2024)

seu valor de associação com a determinada ocorrência. Essa associação pode ser calculada da seguinte forma:

$$associacao_continua = \frac{1000}{distancia_entre_ocorrencia_cruzamento}$$

O valor 1000 foi escolhido arbitrariamente, dado que é necessário apenas fazer a proporção inversa da distância entre a ocorrência e o cruzamento, ou seja, quanto mais distante, menos o vértice recebe influência da ocorrência. Há uma expectativa de que a distribuição contínua da associação entre cruzamentos e ocorrências ampliem as possibilidades estatísticas correlacional entre os grafos de ocorrência e de métricas, operação prevista em nossa metodologia.

4.4 CORRELAÇÕES

Com os grafos construídos precisamos iniciar a etapa de correlações. Executamos a correlação entre cada grafo de métricas e cada grafo de ocorrência, totalizando assim, **dezoito** associações para cada município.

Convém aqui registrar que coeficientes de correlação não são técnicas possíveis de subtender causalidade. Nem é objetivo desta pesquisa, possivelmente, atribuir causalidade a

estrutura urbana dos municípios na ocorrência de crimes, mas sim, investigar quais outras características podem nos ajudar a entender e explicar o fenômeno dos crimes de ruas, mesmo que parcialmente.

O coeficiente de correlação mais utilizado para análises estatísticas é o coeficiente de Pearson. No entanto, um dos pressupostos desta técnica, que mencionamos na seção 2.5.1.2, é de que as variáveis possuam natureza contínua. Como apresentamos anteriormente, possuímos três estratégias para incorporação das ocorrências nos grafos e, apenas a terceira origina uma variável contínua; as demais são de natureza discreta. Com isso, descartamos a utilização desta técnica por ela não se recomendada em todos os nossos cenários.

Esta limitação não se aplica ao coeficiente de correlação de Spearman e, por isso, adotaremos essa técnica. Outra vantagem em utilizar o coeficiente de correlação de Spearman na nossa pesquisa é o fato de que, diferente de Pearson, o coeficiente de Spearman não espera uma relação monótona estritamente linear. Nosso trabalho, por sua vez, não exige que haja uma relação linear entre ocorrências de crimes e medidas de rede, portanto, o coeficiente de Spearman aparece como uma técnica mais adequada.

4.5 FERRAMENTAS

Esta seção tem por objetivo apresentar uma descrição geral das ferramentas computacionais que serão utilizadas ao longo do projeto.

4.5.1 OpenStreetMap

OpenStreetMap é um projeto que segue a produção em pares do Wikipédia cujo objetivo é criar um arranjo de dados de mapa de livre acesso, editáveis e está licenciado sob um novo esquema de direito autoral (HAKLAY; WEBER, 2008). O eixo principal do projeto é o Web Site: www.openstreetmap.org.

4.5.2 OSMnx

OSMnx é uma biblioteca Python para recuperar dados de vias urbanas do OpenStreetMap e então construí-los na forma de grafos do pacote NetworkX (Ver em 4.5.3). Além disso,

OSMnx simplifica e adapta a topologia da rede de vias urbanas automaticamente para garantir que os nós representem, exclusivamente, interseções ou fins de ruas. (BOEING, 2017)

4.5.3 NetworkX

Networkx é uma biblioteca Python para exploração e análise de grafos (redes complexas) e seus algoritmos. Uma biblioteca capaz de fornecer estruturas de dados para representar os mais variados tipos de grafos incluindo grafos simples, direcionados, grafos com arestas paralelas e loops. (HAGBERG et al., 2008)

4.5.4 QGIS


QGIS é uma Sistema de Informação Geográfica (SIG) de Código Aberto licenciado segundo a Licença Pública Geral GNU. Um SIG é uma aplicação que permite visualizar mapas digitais, criar e analisar informações espaciais, adicionar informações a mapas, dentre outras funcionalidades (TEAM, 2009).

5 RESULTADOS

A ocorrência dos crimes é frequentemente observada acontecendo de maneira espacialmente concentrada, como sugere ROSSER et al. (2017). Esse fenômeno tem sido adotado inclusive como fundamento para modelos preditivos de ocorrência de crimes. Dessa maneira, a primeira etapa deste trabalho é visualizar a concentração espacial das ocorrências de crimes em cada uma das cidades envolvidas neste projeto, durante o período que compreende os anos de 2014 a 2022. Além disso, a visualização espacial das ocorrências dos crimes será importante pois já nos indicará de antemão como deverá ficar os grafos de ocorrência de cada cidade. A construção dos grafos de ocorrência é uma etapa importante da nossa metodologia. Para permitir a visualização das ocorrências utilizamos a ferramenta **QGIS** (veja seção 4.5.4) e as camadas municipais foram obtidas através da plataforma **OpenStreetMap** (veja seção 4.5.1).


A seguir, as imagens que representam a visualização das ocorrências de crimes em cada cidade. Utilizamos a técnica de mapa de calor para a visualização pois ela nos ajuda a identificar em quais regiões de cada cidade está ocorrendo maior concentração de ocorrência crimes através de indicações de cores. As regiões com cores mais próximas do tom de vermelho (■) são as regiões onde há mais intensidade de ocorrência de crimes enquanto regiões mais próximas do tom de azul (■) são as regiões onde há menos registros de ocorrência. Regiões sem cores são regiões onde não há registros de crimes. O raio utilizado para determinar a aglutinação das ocorrências, isso é, decidir sobre a concentração de ocorrências em um determinado ponto é de 50 metros na escala real do mapa.

Figura 5.1 – Mapa de calor das ocorrências do município de Alfenas.




Fonte: Autor (2024)

Figura 5.2 – Mapa de calor das ocorrências do município de Itabira.




Fonte: Autor (2024)

Figura 5.3 – Mapa de calor das ocorrências do município de Itajubá.



Fonte: Autor (2024)

Figura 5.4 – Mapa de calor das ocorrências do município de João Monlevade.




Fonte: Autor (2024)

Figura 5.5 – Mapa de calor das ocorrências do município de Lavras.




Fonte: Autor (2024)

Figura 5.6 – Mapa de calor das ocorrências do município de Ouro Preto.



Fonte: Autor (2024)

Figura 5.7 – Mapa de calor das ocorrências do município de São João Del Rei.



Fonte: Autor (2024)

Figura 5.8 – Mapa de calor das ocorrências do município de Viçosa.



Fonte: Autor (2024)

A concentração das ocorrências podem ser descritas também na forma de dados numéricos. De acordo com nossa metodologia as ocorrências serão associadas com o(s) vértice(s) mais próximo(s) (em algumas das abordagens apresentadas uma ocorrência poderá até estar associada a mais de um vértice). Assim sendo, podemos apresentar uma relação de ocorrência por vértice para ampliar o entendimento sobre a concentração delas dentro da estrutura urbana.

Chamaremos de **concentração de vértices total** (CVT) a relação do número de vértices que possuem ao menos uma ocorrência associada com o número total de vértices que compõem a estrutura urbana da cidade. Essa relação pode ser descrita da seguinte forma:

$$cvt = \frac{num_vertices_ocorrendia}{num_vertices_totais}$$

Por fim, chamaremos também de **espalhamento de ocorrência total** (EOT) a relação do número total de ocorrências registradas com o número total de vértices que compõem a estrutura urbana da cidade, associando cada ocorrência a um único vértice e cada vértice a uma

única ocorrência. Dessa forma, poderemos entender o quanto o total de ocorrências consegue "cobrir" a estrutura da cidade.

$$eot = \frac{num_ocorrencias_totais}{num_vertices_totais}$$

A tabela 5.1 consolida os valores de *CVT* e *EOT* para cada uma das cidades envolvidas:

Tabela 5.1 – Resultado do cálculo de **CVT** e **EOT** para as cidades.

Cidade	CVT	EOT
Alfenas	29%	63%
Itabira	23%	49%
Itajubá	15%	26%
João Monlevade	29%	57%
Lavras	10%	15%
Ouro Preto	20%	43%
São João Del Rei	7%	9%
Viçosa	22%	68%

Fonte: Autor (2024)

A tabela 5.1 ilustra a concentração espacial de ocorrência dos crimes. O objetivo era avaliar se as ocorrências estavam realmente sendo "aglomeradas" em alguns vértices ou regiões. Assim sendo, quanto menor o valor de **CVT** e maior o valor de **EOT**, mais concentração está acontecendo naquele município. As cidades de São João Del Rei e Lavras, que possuem menor concentração de crimes, também são as que menos possuem registros de ocorrência.

5.1 GRAFOS DE OCORRÊNCIA E GRAFOS DE MEDIDAS

Antes de iniciarmos a análise da correlação entre os grafos de ocorrência e os grafos de medidas, pode ser interessante a visualização de cada um deles. O objetivo desta visualização é o mesmo das anteriores: identificar visualmente as regiões onde ocorrem maior concentração do fenômeno observado, sendo que aqui os fenômenos são tanto as estratégias adotadas para assimilar as ocorrências ao grafo da cidade, quanto as características da rede (medidas de centralidade) que representam tal município.

Para a construção da visualização de ambos grafos de ocorrência e grafos de métricas utilizamos a técnica de mapa de calor para ajudar na identificação das áreas com regiões de maior incidência de ocorrência de acordo com a estratégia e/ou medida avaliada. O *colormap* utilizado para pintar os grafos é o *rainbow* e pode ser melhor compreendido aqui.

Por ser uma quantidade grande de figuras, as imagens com os grafos de ocorrência e características de rede de cada cidade se encontram no apêndice A deste trabalho.

5.2 CORRELAÇÕES

As particularidades dos dados desta pesquisa sugerem que utilizemos a correlação de Spearman, como mostrado na seção 2. Abaixo abordaremos melhor esses aspectos.

5.2.1 CORRELAÇÃO DE SPEARMAN

Nesta seção faremos a apresentação das correlações em cada um dos municípios envolvidos na pesquisa e, em seguida, uma breve discussão sobre os resultados de cada um deles. No entanto, no capítulo de Discussão (6), ampliaremos o debate e abordaremos sobre o conjunto geral dos resultados de todos os municípios.

Assim como já mencionado na seção 2.5 onde abordamos sobre os coeficientes de correlação, relembramos aqui que nossas variáveis que quantificam a associação de crimes nas duas primeiras estratégias (veja seção 4.2.1) possuem uma natureza discreta e com pouca diversidade de valores, por esses motivos reforçamos o uso da correlação de **Spearman** que é uma técnica não paramétrica robusta para essas características dos dados.

Precisamos rememorar brevemente também que nós utilizaremos a abordagem convencional apresentada e discutida na seção 2.5 para a interpretação dos coeficientes de correlação.

As colunas das tabelas 5.2 até 5.9 representam as seguintes medidas:

- a) **grau:** centralidade de grau;
- b) **proximidade:** centralidade por proximidade;
- c) **mediação:** centralidade por intermediação;
- d) **autovetor:** centralidade de autovetor;
- e) **PR:** Page Rank;
- f) **dist. univers.:** Distância para universidade.

5.2.1.1 ALFENAS

A tabela a seguir 5.2 apresenta os valores de correlação entre cada estratégia e medida de rede.

Tabela 5.2 – Coeficiente de correlação de Spearman para o município de Alfenas.

Estratégia/Medida	Grau	Proximidade	Intermediação	Autovetor	PR	Dist. Univers.
Primeira	0,14	0,35	0,18	0,21	0,06	-0,34
Segunda	0,15	0,49	0,22	0,30	0,05	-0,47
Terceira	0,16	0,53	0,22	0,35	0,05	-0,53

Fonte: Autor (2024)

Considerando a abordagem convencional para a interpretação dos coeficientes de correlação de Spearman, podemos observar que a medida Page Rank apresenta correlação desprezível com a ocorrência de crimes em todas as estratégias adotadas.

Enquanto isso, as medidas de centralidade de grau, de intermediação e de autovetor possuem uma correlação fraca com as ocorrências de crime em todas as estratégias.

Por outro lado, observamos que as medidas de centralidade por proximidade e distância em relação à universidade exibem uma correlação fraca na primeira estratégia, mas uma correlação moderada nas demais estratégias. Assim sendo, constatamos que essas medidas são as que mais se correlacionam com a incidência de crimes na cidade de Alfenas.

Estes resultados são, de certa forma, esperados, uma vez que, ao analisarmos o mapa de calor das ocorrências criminais apresentado no início deste capítulo, podemos notar uma concentração de crimes na área central da cidade. Adicionalmente, é importante ressaltar que a sede da Universidade Federal de Alfenas está localizada nessa mesma região central.

5.2.2 ITABIRA

A tabela a seguir 5.3 apresenta os valores de correlação entre cada estratégia e medida de rede.

Tabela 5.3 – Coeficiente de correlação de Spearman para o município de Itabira.

Estratégia/Medida	Grau	Proximidade	Intermediação	Autovetor	PR	Dist. Univers.
Primeira Estratégia	0,03	0,16	0,06	-0,02	-0,01	0,13
Segunda Estratégia	0,02	0,26	0,11	-0,05	-0,01	0,22
Terceira Estratégia	0,03	0,32	0,13	-0,03	0,00	0,24

Fonte: Autor (2024)

Em Itabira, podemos observar que todos os coeficientes de correlação apresentaram uma magnitude de relação desprezível ou fraca, considerando a abordagem convencional.

No entanto, vale destacar que as medidas centralidade por proximidade e dist. universidade foram as medidas com maior magnitude de correlação. A centralidade por proximidade, principalmente, chama atenção na comparação visual dos grafos.

5.2.3 ITAJUBÁ

A tabela a seguir 5.4 apresenta os valores de correlação entre cada estratégia e medida de rede calculada.

Tabela 5.4 – Coeficiente de correlação de Spearman para o município de Itajubá.

Estratégia/Medida	Grau	Proximidade	Intermediação	Autovetor	PR	Dist. Univers.
Primeira Estratégia	0,01	0,24	0,17	-0,01	0,03	-0,22
Segunda Estratégia	0,00	0,39	0,24	0,01	0,01	-0,36
Terceira Estratégia	0,01	0,44	0,25	0,03	0,01	-0,41

Fonte: Autor (2024)

Em Itajubá, a maioria dos coeficientes de correlação foram considerados fracos ou desprezíveis. No entanto, merece destaque a centralidade por proximidade nas segunda e terceira estratégias, que mostraram uma correlação moderada segundo os critérios convencionais. A distância da universidade também apresentou uma correlação próxima da moderada na segunda estratégia e alcançou uma correlação moderada na terceira estratégia.

5.2.4 JOÃO MONLEVADE

A tabela a seguir 5.5 apresenta os valores de correlação entre cada estratégia e medida de rede calculada.

Tabela 5.5 – Coeficiente de correlação de Spearman para o município de João Monlevade.

Estratégia/Medida	Grau	Proximidade	Intermediação	Autovetor	PR	Dist. Univers.
Primeira Estratégia	0,03	0,09	0,12	0,07	0,00	0,03
Segunda Estratégia	-0,01	0,14	0,18	0,09	-0,01	0,05
Terceira Estratégia	0,00	0,19	0,19	0,10	-0,01	-0,01

Fonte: Autor (2024)

Em João Monlevade, embora a medida de centralidade por proximidade tenha apresentado a maior magnitude de correlação entre as características de rede, todas as pontuações foram muito baixas, não permitindo observar correlações significativas além das consideradas fracas ou desprezíveis neste município.

5.2.5 LAVRAS

A tabela a seguir 5.6 apresenta os valores de correlação entre cada estratégia e medida de rede calculada.

Tabela 5.6 – Coeficiente de correlação de Spearman para o município de Lavras.

Estratégia/Medida	Grau	Proximidade	Intermediação	Autovetor	PR	Dist. Univers.
Primeira Estratégia	-0,01	0,20	0,10	0,12	-0,01	-0,10
Segunda Estratégia	-0,02	0,32	0,16	0,18	0,01	-0,14
Terceira Estratégia	-0,01	0,34	0,17	0,20	0,01	-0,16

Fonte: Autor (2024)

Em Lavras, não encontramos nenhuma medida que tenha alcançado uma correlação moderada. No entanto, destacamos que a medida de centralidade por proximidade apresenta a maior magnitude de correlação entre todas as características de rede analisadas. Além disso, a medida de autovetor em Lavras se destaca ao mostrar uma pontuação de correlação superior às observadas na maioria dos demais municípios.

5.2.6 OURO PRETO

A tabela a seguir 5.7 apresenta os valores de correlação entre cada estratégia e medida de rede calculada.

Tabela 5.7 – Coeficiente de correlação de Spearman para o município de Ouro Preto.

Estratégia/Medida	Grau	Proximidade	Intermediação	Autovetor	PR	Dist. Univers.
Primeira Estratégia	0,01	0,35	0,20	0,04	-0,01	-0,15
Segunda Estratégia	0,00	0,48	0,23	0,05	-0,01	-0,19
Terceira Estratégia	0,03	0,52	0,26	0,07	0,01	-0,24

Fonte: Autor (2024)

Em Ouro Preto, observamos uma correlação moderada para a medida de centralidade por proximidade na segunda e também na terceira estratégia. Além disso, já na primeira estratégia é possível observar um valor próximo de uma correlação moderada. As demais medidas possuem um valor considerado fraco ou desprezível.

5.2.7 SÃO JOÃO DEL REI

A tabela a seguir 5.8 apresenta os valores de correlação entre cada estratégia e medida de rede calculada.

Tabela 5.8 – Coeficiente de correlação de Spearman para o município de São João Del Rei.

Estratégia/Medida	Grau	Proximidade	Intermediação	Autovetor	PR	Dist. Univers.
Primeira Estratégia	0,00	0,20	0,12	-0,08	0,00	-0,15
Segunda Estratégia	-0,01	0,34	0,16	-0,12	-0,01	-0,26
Terceira Estratégia	0,00	0,35	0,16	-0,11	-0,01	-0,27

Fonte: Autor (2024)

Em São João Del Rei, todas as medidas foram classificadas como fracas ou desprezíveis conforme a abordagem convencional de interpretação. No entanto, é importante destacar que a medida de centralidade por proximidade apresenta o maior valor de correlação, quase alcançando uma interpretação moderada na segunda e terceira estratégias.

5.2.8 VIÇOSA

A tabela a seguir 5.9 apresenta os valores de correlação entre cada estratégia e medida de rede calculada.

Tabela 5.9 – Coeficiente de correlação de Spearman para o município de Viçosa.

Estratégia/Medida	Grau	Proximidade	Intermediação	Autovetor	PR	Dist. Univers.
Primeira Estratégia	0,03	0,26	0,14	0,07	0,05	-0,16
Segunda Estratégia	0,03	0,34	0,18	0,10	0,05	-0,15
Terceira Estratégia	0,06	0,37	0,20	0,14	0,05	-0,23

Fonte: Autor (2024)

O município de Viçosa seguiu um padrão semelhante ao observado em São João Del Rei, onde todas as medidas foram classificadas como fracas ou desprezíveis. Vale destacar especialmente a medida de centralidade por proximidade, que apresenta o maior valor de correlação, quase atingindo uma interpretação moderada nas segunda e terceira estratégias.

6 DISCUSSÃO

Nesta pesquisa, utilizamos dados da Polícia Militar de Minas Gerais a respeito da ocorrência de crimes de rua. A partir da utilização de técnicas de medidas de redes complexas, construímos grafos que pudessem ser relacionados com as ocorrências anteriormente obtidas, com a finalidade de identificar regiões de concentração espacial onde esses crimes ocorrem no interior de cada município, como foi apontado por ROSSER et al. (2017).

Julgamos, neste estudo, que as medidas de centralidade de redes complexas calculadas a partir da rede viária de cada município pudesse ser uma técnica que nos ajudasse na compreensão do fenômeno da concentração espacial de crimes. A partir de técnicas estatísticas buscamos correlacionar as regiões que ocorreram crimes nos dados históricos, com as regiões de maior centralidade na rede viária.

Os resultados mostram que a medida de centralidade que melhor se correlaciona com as regiões de ocorrência de crimes é a centralidade por proximidade (*closeness centrality*). Esta medida foi a melhor em sete das oito cidades desta pesquisa, sendo menos expressiva apenas na cidade de João Monlevade. Além disso, a centralidade por proximidade foi a única medida de centralidade de redes complexas que conseguiu possuir uma correlação moderada com a região dos crimes, sendo observada nas cidades de Alfenas, Itajubá e Ouro Preto. Ainda assim, em cidades como São João Del Rei, Viçosa e Itabira, a magnitude da correlação ficou próxima de ser considerada moderada segundo a abordagem convencional para interpretação de correlação de Spearman.

A medida de centralidade por proximidade calcula na rede os nós que são mais capaz de espalhar informação, medindo para cada um o quão próximo este está dos demais. Ou seja, nós com alta pontuação na centralidade por proximidade possui as menores distâncias para os demais (CENTENO et al., 2022).

Nas cidades, esses nós (cruzamentos) que possuem alta pontuação de centralidade por proximidade, estão geralmente associados a região central. A região central das cidades são, frequentemente, aquelas onde há grande fluxo de circulação de pessoas e de comércio. Essas características tornam essas regiões atrativas para a ocorrência destes crimes, como aponta XIANG; SHENG; LIAO (2023). No entanto, concluir que nas cidades observadas nesta pesquisa, as áreas com alta pontuação de centralidade por proximidade correspondem necessariamente às regiões centrais requer investigações mais detalhadas em estudos futuros. Se essa correla-

ção se confirmar, poderia simplificar análises criminológicas, já que calcular a centralidade por proximidade das estruturas urbanas é uma tarefa relativamente simples.

Neste trabalho, também adicionamos a medida de distância para universidade, e como mencionado anteriormente, consiste em atribuir para cada nó uma pontuação a partir da distância dele até a universidade federal da respectiva cidade. Nós adicionamos esta medida pelo fato de que todos os município são ditos "universitários". No entanto, em algumas cidade esta medida obteve magnitudes de correlação (negativa) mais elevadas, como é o caso das cidades de Alfenas e Itajubá, podendo mesmo até ser considerada uma correlação moderada. No entanto, observamos que as cidades onde essa medida tem maior magnitude de correlação, são cidades onde a universidade se encontra na mesma região da centralidade por proximidade. Enquanto essa medida tende a ser menor quando a universidade está em regiões mais distante da região da centralidade por proximidade como é o caso de Ouro Preto. A localização de cada universidade federal pode ser vista no apêndice B.

Essa observação pode ser interessante, pois pode nos indicar que não há necessariamente ocorrências de crimes intrínsecas à população estudantil das cidades e, que a depender da localização da universidade, poderemos observar uma melhora na percepção de segurança desta população.

A medida de centralidade de grau apresentou valores de correlação desprezíveis em todas as estratégias e cidades observadas, e possivelmente, isso se deve ao fato das redes viárias das cidades serem homogêneas em relação ao grau, enquanto que as ocorrências de crimes tendem a serem heterogêneas, tendo uma maior concentração numa determinada região da rede.

A homogeneidade da rede com relação ao grau é melhor observada quando visualizamos os grafos de medidas de centralidade de grau para cada cidade que estão no apêndice A. As demais medidas apresentaram magnitude de correlação muito fracas algumas até desprezíveis, por isso deixamos de desenvolver qualquer análise mais aprofundada sobre elas. Page Rank e centralidade de grau foram consideradas medidas desprezíveis em todas as três estratégias e em todas as cidades observadas. Para a medida de autovetor 50% da sua correlação com as regiões de crime nos municípios foram desprezíveis, enquanto os outros 50% foram fracas. Enquanto que, para a medida de centralidade por intermediação quase a sua totalidade (92%) foi considerada uma correlação de magnitude fraca, muito próxima a uma magnitude desprezível.

Durante a pesquisa, observamos alguns fatos que podem ser considerados uma ameaça a validade da pesquisa. O primeiro deles é quanto a estratégia de incorporar as ocorrências

ao grafo. Neste trabalho, adotamos três estratégias diferentes para fazer a incorporação. Cada forma buscava satisfazer um objetivo em particular. No entanto, todas as estratégias são peculiares deste trabalho, implicando que outras formas de incorporar as ocorrências no grafo possam gerar diferentes resultados.

A segunda ameaça se refere aos dados. Acreditamos que uma base de dados com uma maior quantidade de ocorrências e em cidades de maior porte, como por exemplo cidades metropolitanas, podem colaborar melhor para a correlação entre os crimes e as medidas de centralidade da rede viária, uma vez que uma maior quantidade de ocorrências podem evidenciar melhor a concentração espacial do crime.

Destacamos também as questões éticas envolvendo este tipo de pesquisa. Ao simplificar questões sociais de grande relevância, como a incidência de crimes, corremos o risco de reforçar preconceitos e até mesmo agravar o problema, como apontado por O'NEIL; ABRAHAM (2021). O objetivo deste estudo é identificar uma variável ou fator que possa auxiliar na compreensão das ocorrências criminais nas cidades analisadas, potencialmente sendo aplicável em modelos preditivos. No entanto, é importante ressaltar que este trabalho se baseia em dados históricos fornecidos pela Polícia Militar de Minas Gerais, e, portanto, os resultados são influenciados pelos vieses cognitivos presentes nessas informações. Este aspecto levanta um alerta sobre as implicações éticas que permeiam esta pesquisa.

REFERÊNCIAS

- ANDERSON, A. L.; HUGHES, L. A. Exposure to situations conducive to delinquent behavior: The effects of time use, income, and transportation. **Journal of Research in Crime and Delinquency**, v. 46, p. 5–34, 2 2009. ISSN 00224278.
- ARAÚJO, A. F. et al. Topologias e tipologias arquitetônicas. **Paranoá: cadernos de arquitetura e urbanismo**, Programa de Pós-Graduação em Arquitetura e Urbanismo - Univ. de Brasília, 12 2015. ISSN 1677-7395.
- BAAL, P. van. **Computer simulations of criminal deterrence**. [S.l.: s.n.], 2004.
- BEAVON, D. J. K.; BRANTINGHAM, P. L.; BRANTINGHAM, P. J. **THE INFLUENCE OF STREET NETWORKS ON THE PATTERNING OF PROPERTY OFFENSES**. 1994.
- BENINCASA, C. et al. **Page Rank Algorithm**. 2017. Disponível em: <<https://www.researchgate.net/publication/268335545>>.
- BITOUN, J. **TIPOLOGIA DAS CIDADES BRASILEIRAS E POLÍTICAS TERRITORIAIS: PISTAS PARA REFLEXÃO**. 2009.
- BOEING, G. Osmnx: A python package to work with graph-theoretic openstreetmap street networks. **The Journal of Open Source Software**, The Open Journal, v. 2, p. 215, 4 2017.
- BRANTINGHAM, P.; BRANTINGHAM, P. **Criminality of place Crime generators and crime attractors**. 1995.
- BRITTO, D. et al. **Desvendando os Mistérios do Coeficiente de Correlação de Pearson (r)**. 2009.
- BURGUILLO, J. C. **Complex Networks**. [S.l.: s.n.], 2018. 35-56 p.
- CENTENO, E. G. Z. et al. A hands-on tutorial on network and topological neuroscience. **Brain Structure and Function**, Springer Science and Business Media Deutschland GmbH, v. 227, p. 741–762, 4 2022. ISSN 18632661.
- COZENS, P. M. Urban planning and environmental criminology: Towards a new perspective for safer cities. **Planning Practice and Research**, v. 26, p. 481–508, 8 2011. ISSN 02697459.
- DANTAS, A. **Folguedos, pontes e navegador de posicionamento global por satélite**. 2010. Disponível em: <<http://www.autoentusiastasclassic.com.br/2010/08/folguedos-pontes-e-gps.html?m=0>>.
- ELEUTÉRIO, F. **Análise do conceito de crime**. 2005.
- FARIA, A. H. P. de; DINIZ, A. M. A.; ALVES, D. F. C. Espaço de ação de criminosos e sua correlação com a paisagem urbana: um estudo de análise centrográfica e distribuição de atratores para o crime. **Geosul**, Universidade Federal de Santa Catarina (UFSC), v. 35, p. 623–653, 6 2020. ISSN 0103-3964.
- FELSON, M.; GOTTFREDSON, M. **Social Indicators of Adolescent Activities near Peers and Parents**. 1984. 709-714 p.

- FEOFILOFF, P.; KOHAYAKAWA, Y.; WAKABAYASHI, Y. **Uma Introdução Sucinta à Teoria dos Grafos**. 2011. Disponível em: <<http://www.ime.usp.br/~pf/teoriadosgrafos/>>.
- GERRITSEN, C. **Caught in the Act: Investigation Crime by Agent-Based Simulation**. [S.l.: s.n.], 2010.
- HAGBERG, A. A. H. et al. **Exploring Network Structure, Dynamics, and Function using NetworkX**. 2008. Disponível em: <http://conference.scipy.org/proceedings/SciPy2008/paper_2>.
- HAKLAY, M.; WEBER, P. **openstreetMap: User-Generated street Maps**. 2008. Disponível em: <www.openstreetmap.org>.
- IBGE. **Panorama de Minhas Gerais e cidades**. 2020. Disponível em: <<https://cidades.ibge.gov.br/brasil/mg/panorama>>.
- JIANG, B.; CLARAMUNT, C. Topological analysis of urban street networks. **Environment and Planning B: Planning and Design**, Pion Limited, v. 31, p. 151–162, 2004. ISSN 02658135.
- MAO, Y. et al. **Review of Empirical Studies on Relationship between Street Environment and Crime**. [S.l.]: SAGE Publications Inc., 2021. 187-202 p.
- MATA, A. S. da. Complex networks: a mini-review. **Brazilian Journal of Physics**, Springer, v. 50, p. 658–672, 10 2020. ISSN 16784448.
- NETTO, P. O. B. **Grafos: Teoria, Modelos, Algoritmos**. [S.l.: s.n.], 1996.
- O'NEIL, C.; ABRAHAM, R. **Algoritmos de Destruição em Massa**. Editora Rua do Sabão, 2021. ISBN 9786586460094. Disponível em: <<https://books.google.com.br/books?id=nEUvEAAAQBAJ>>.
- ROSSER, G. et al. Predictive crime mapping: Arbitrary grids or street networks? **Journal of Quantitative Criminology**, Springer New York LLC, v. 33, p. 569–594, 9 2017. ISSN 07484518.
- SCHOBER, P.; SCHWARTE, L. A. Correlation coefficients: Appropriate use and interpretation. **Anesthesia and Analgesia**, Lippincott Williams and Wilkins, v. 126, p. 1763–1768, 5 2018. ISSN 15267598.
- SHEVLYAKOV, G. L.; OJA, H. **Robust Correlation**. 2016.
- SMITH, G. J.; MOSES, L. B.; CHAN, J. The challenges of doing criminology in the big data era: Towards a digital and data-driven approach. **British Journal of Criminology**, Oxford University Press, v. 57, p. 259–274, 3 2017. ISSN 14643529.
- SOARES, M.; SABOYA, R. T. de. Environmental factors of the crime occurrence: A framework for the analysis of available evidence. **Urbe**, Editora CHAMPAGNAT, v. 11, 2019. ISSN 21753369.
- SOHN, D.-W. Residential crimes and neighbourhood built environment: Assessing the effectiveness of crime prevention through environmental design (cpted). **Cities**, v. 52, p. 86–93, 2016. ISSN 0264-2751. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0264275115300159>>.

TEAM, Q. D. **QGIS Geographic Information System**. [S.l.], 2009. Disponível em: <<http://qgis.org>>.

TILLEY, N. **Problem-solving street crime : practical lessons from the Street Crime Initiative**. [S.l.]: Home Office, 2004. 96 p. ISBN 1844734862.

TOKORO, P. M.; COSTA, S. F. **INTRODUÇÃO À TOPOLOGIA ALGÉBRICA 1**. 2021.

WARR, M. **MAKING DELINQUENT FRIENDS: ADULT SUPERVISION AND CHILDREN'S AFFILIATIONS**. 2005. 77 p.

WHITE, G. F. Neighborhood permeability and burglary rates. **Justice Quarterly**, v. 7, p. 57–68, 1990. ISSN 17459109.

XIANG, L.; SHENG, J.; LIAO, P. Understanding the relationship between the spatial configuration and the crime rate of downtown eastside in vancouver, canada. **Habitat International**, Elsevier Ltd, v. 137, 7 2023. ISSN 01973975.


XING, W.; GHORBANI, A. **Weighted PageRank Algorithm**. 2004.

YUE, H. et al. Modelling the effects of street permeability on burglary in wuhan, china. **Applied Geography**, Elsevier Ltd, v. 98, p. 177–183, 9 2018. ISSN 01436228.

APÊNDICE A – GRAFOS


Este apêndice é dedicado exclusivamente à apresentação de imagens de grafos que complementam e ilustram as análises discutidas no corpo principal desta dissertação. As figuras aqui incluídas representam visualmente as estruturas, relações e dinâmicas estudadas, oferecendo uma percepção mais clara e detalhada dos dados e resultados. Cada grafo é acompanhado de uma legenda explicativa, facilitando a interpretação e compreensão das informações apresentadas.

Figura 1 – Ilustração do grafo da primeira estratégia para a cidade de Alfenas.




Fonte: Autor (2024)

Figura 2 – Ilustração do grafo da segunda estratégia para a cidade de Alfenas.




Fonte: Autor (2024)

Figura 3 – Ilustração do grafo da terceira estratégia para a cidade de Alfenas.




Fonte: Autor (2024)

Figura 4 – Ilustração do grafo de centralidade de grau para a cidade de Alfenas.




Fonte: Autor (2024)

Figura 5 – Ilustração do grafo de centralidade de proximidade para a cidade de Alfenas.




Fonte: Autor (2024)

Figura 6 – Ilustração do grafo de centralidade de intermediação para a cidade de Alfenas.



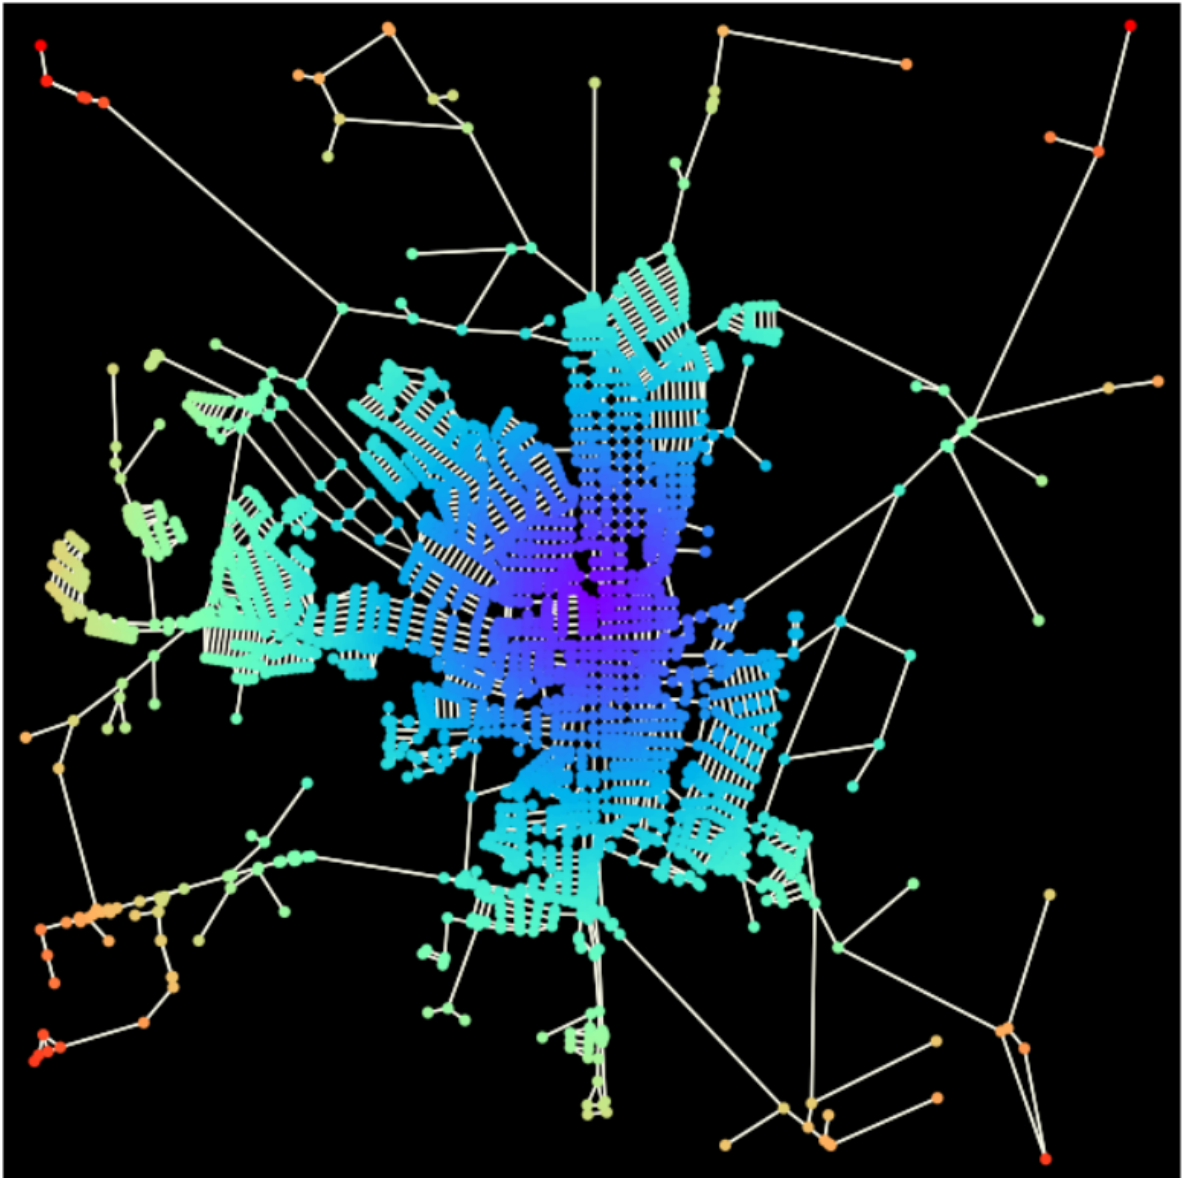
Fonte: Autor (2024)

Figura 7 – Ilustração do grafo de centralidade de autovetor para a cidade de Alfenas.




Fonte: Autor (2024)

Figura 8 – Ilustração do grafo de centralidade Page Rank para a cidade de Alfenas.




Fonte: Autor (2024)

Figura 9 – Ilustração do grafo para a medida de distância Universidade na cidade de Alfenas.




Fonte: Autor (2024)

Figura 10 – Ilustração do grafo da primeira estratégia para a cidade de Itabira.




Fonte: Autor (2024)

Figura 11 – Ilustração do grafo da segunda estratégia para a cidade de Itabira.




Fonte: Autor (2024)

Figura 12 – Ilustração do grafo da terceira estratégia para a cidade de Itabira.




Fonte: Autor (2024)

Figura 13 – Ilustração do grafo de centralidade de grau para a cidade de Itabira.




Fonte: Autor (2024)

Figura 14 – Ilustração do grafo de centralidade de proximidade para a cidade de Itabira.




Fonte: Autor (2024)

Figura 15 – Ilustração do grafo de centralidade de intermediação para a cidade de Itabira.




Fonte: Autor (2024)

Figura 16 – Ilustração do grafo de centralidade de autovetor para a cidade de Itabira.




Fonte: Autor (2024)

Figura 17 – Ilustração do grafo de centralidade Page Rank para a cidade de Itabira.




Fonte: Autor (2024)

Figura 18 – Ilustração do grafo para a medida de **distância universidade** na cidade de Itabira.




Fonte: Autor (2024)

Figura 19 – Ilustração do grafo da primeira estratégia para a cidade de Itajubá.




Fonte: Autor (2024)

Figura 20 – Ilustração do grafo da segunda estratégia para a cidade de Itajubá.




Fonte: Autor (2024)

Figura 21 – Ilustração do grafo da terceira estratégia para a cidade de Itajubá.




Fonte: Autor (2024)

Figura 22 – Ilustração do grafo de centralidade de grau para a cidade de Itajubá.




Fonte: Autor (2024)

Figura 23 – Ilustração do grafo de centralidade de proximidade para a cidade de Itajubá.




Fonte: Autor (2024)

Figura 24 – Ilustração do grafo de centralidade de intermediação para a cidade de Itajubá.




Fonte: Autor (2024)

Figura 25 – Ilustração do grafo de centralidade de autovetor para a cidade de Itajubá.




Fonte: Autor (2024)

Figura 26 – Ilustração do grafo de centralidade Page Rank para a cidade de Itajubá.




Fonte: Autor (2024)

Figura 27 – Ilustração do grafo para a medida de **distância universidade** na cidade de Itajubá.




Fonte: Autor (2024)

Figura 28 – Ilustração do grafo da primeira estratégia para a cidade de João Monlevade.




Fonte: Autor (2024)

Figura 29 – Ilustração do grafo da segunda estratégia para a cidade de João Monlevade.




Fonte: Autor (2024)

Figura 30 – Ilustração do grafo da terceira estratégia para a cidade de João Monlevade.




Fonte: Autor (2024)

Figura 31 – Ilustração do grafo de centralidade de grau para a cidade de João Monlevade.




Fonte: Autor (2024)

Figura 32 – Ilustração do grafo de centralidade de proximidade para a cidade de João Monlevade.




Fonte: Autor (2024)

Figura 33 – Ilustração do grafo de centralidade de intermediação para a cidade de João Monlevade.




Fonte: Autor (2024)

Figura 34 – Ilustração do grafo de centralidade de autovetor para a cidade de João Monlevade.




Fonte: Autor (2024)

Figura 35 – Ilustração do grafo de centralidade Page Rank para a cidade de João Monlevade.




Fonte: Autor (2024)

Figura 36 – Ilustração do grafo para a medida de **distância universidade** na cidade de João Monlevade.




Fonte: Autor (2024)

Figura 37 – Ilustração do grafo da primeira estratégia para a cidade de Lavras.




Fonte: Autor (2024)

Figura 38 – Ilustração do grafo da segunda estratégia para a cidade de Lavras.




Fonte: Autor (2024)

Figura 39 – Ilustração do grafo da terceira estratégia para a cidade de Lavras.




Fonte: Autor (2024)

Figura 40 – Ilustração do grafo de centralidade de grau para a cidade de Lavras.




Fonte: Autor (2024)

Figura 41 – Ilustração do grafo de centralidade de proximidade para a cidade de Lavras.




Fonte: Autor (2024)

Figura 42 – Ilustração do grafo de centralidade de intermediação para a cidade de Lavras.




Fonte: Autor (2024)

Figura 43 – Ilustração do grafo de centralidade de autovetor para a cidade de Lavras.




Fonte: Autor (2024)

Figura 44 – Ilustração do grafo de centralidade Page Rank para a cidade de Lavras.




Fonte: Autor (2024)

Figura 45 – Ilustração do grafo para a medida de **distância universidade** na cidade de Lavras.




Fonte: Autor (2024)

Figura 46 – Ilustração do grafo da primeira estratégia para a cidade de Ouro Preto.




Fonte: Autor (2024)

Figura 47 – Ilustração do grafo da segunda estratégia para a cidade de Ouro Preto.




Fonte: Autor (2024)

Figura 48 – Ilustração do grafo da terceira estratégia para a cidade de Ouro Preto.




Fonte: Autor (2024)

Figura 49 – Ilustração do grafo de centralidade de grau para a cidade de Ouro Preto.




Fonte: Autor (2024)

Figura 50 – Ilustração do grafo de centralidade de proximidade para a cidade de Ouro Preto.




Fonte: Autor (2024)

Figura 51 – Ilustração do grafo de centralidade de intermediação para a cidade de Ouro Preto.




Fonte: Autor (2024)

Figura 52 – Ilustração do grafo de centralidade de autovetor para a cidade de Ouro Preto.




Fonte: Autor (2024)

Figura 53 – Ilustração do grafo de centralidade Page Rank para a cidade de Ouro Preto.




Fonte: Autor (2024)

Figura 54 – Ilustração do grafo para a medida de **distância universidade** na cidade de Ouro Preto.




Fonte: Autor (2024)

Figura 55 – Ilustração do grafo da primeira estratégia para a cidade de São João Del Rei.




Fonte: Autor (2024)

Figura 56 – Ilustração do grafo da segunda estratégia para a cidade de São João Del Rei.




Fonte: Autor (2024)

Figura 57 – Ilustração do grafo da terceira estratégia para a cidade de São João Del Rei.




Fonte: Autor (2024)

Figura 58 – Ilustração do grafo de centralidade de grau para a cidade de São João Del Rei.




Fonte: Autor (2024)

Figura 59 – Ilustração do grafo de centralidade de proximidade para a cidade de São João Del Rei.




Fonte: Autor (2024)

Figura 60 – Ilustração do grafo de centralidade de intermediação para a cidade de São João Del Rei.




Fonte: Autor (2024)

Figura 61 – Ilustração do grafo de centralidade de autovetor para a cidade de São João Del Rei.




Fonte: Autor (2024)

Figura 62 – Ilustração do grafo de centralidade Page Rank para a cidade de São João Del Rei.




Fonte: Autor (2024)

Figura 63 – Ilustração do grafo para a medida de **distância universidade** na cidade de São João Del Rei.




Fonte: Autor (2024)

Figura 64 – Ilustração do grafo da primeira estratégia para a cidade de Viçosa.




Fonte: Autor (2024)

Figura 65 – Ilustração do grafo da segunda estratégia para a cidade de Viçosa.




Fonte: Autor (2024)

Figura 66 – Ilustração do grafo da terceira estratégia para a cidade de Viçosa.




Fonte: Autor (2024)

Figura 67 – Ilustração do grafo de centralidade de grau para a cidade de Viçosa.




Fonte: Autor (2024)

Figura 68 – Ilustração do grafo de centralidade de proximidade para a cidade de Viçosa.




Fonte: Autor (2024)

Figura 69 – Ilustração do grafo de centralidade de intermediação para a cidade de Viçosa.




Fonte: Autor (2024)

Figura 70 – Ilustração do grafo de centralidade de autovetor para a cidade de Viçosa.




Fonte: Autor (2024)

Figura 71 – Ilustração do grafo de centralidade Page Rank para a cidade de Viçosa.



Fonte: Autor (2024)

Figura 72 – Ilustração do grafo para a medida de **distância universidade** na cidade de Viçosa.



Fonte: Autor (2024)

APÊNDICE B – LOCALIZAÇÃO DAS UNIVERSIDADES

Este apêndice é dedicado exclusivamente à apresentação de imagens de satélite retiradas do Google Earth com o objetivo de ilustrar a localização das universidades dentro de cada município. Cada imagem é acompanhada de uma legenda explicativa, facilitando a interpretação e compreensão das informações apresentadas.

Figura 73 – Imagem de satélite retiradas do Google Earth destacando a localização da Universidade Federal de Alfenas.




Fonte: Google Earth (2024)

Figura 74 – Imagem de satélite retiradas do Google Earth destacando a localização da Universidade Federal de Itajubá - Campus Itabira.



Fonte: Google Earth (2024)

Figura 75 – Imagem de satélite retiradas do Google Earth destacando a localização da Universidade Federal de Itajubá.



Fonte: Google Earth (2024)

Figura 76 – Imagem de satélite retiradas do Google Earth destacando a localização da Universidade Federal de Ouro Preto - Campus João Monlevade.



Fonte: Google Earth (2024)

Figura 77 – Imagem de satélite retiradas do Google Earth destacando a localização da Universidade Federal de Lavras.



Fonte: Google Earth (2024)

Figura 78 – Imagem de satélite retiradas do Google Earth destacando a localização da Universidade Federal de Ouro Preto.



Fonte: Google Earth (2024)

Figura 79 – Imagem de satélite retiradas do Google Earth destacando a localização da Universidade Federal de São João del Rei.



Fonte: Google Earth (2024)

Figura 80 – Imagem de satélite retiradas do Google Earth destacando a localização da Universidade Federal de Viçosa.



Fonte: Google Earth (2024)