INTEGRAÇÃO ENTRE METODOLOGIA MULTICRITÉRIO E SISTEMAS DE INFORMAÇÃO GEOGRÁFICA PARA CLASSIFICAÇÃO DE ÁREAS DE VULNERABILIDADE

Ciro José Jardim de Figueiredo
Universidade Federal de Pernambuco
Av. Prof° Moraes Rego, 1235 – Cidade Universitária, Recife – PE
ciro.figueiredo@ufpe.br

Débora Viana e Sousa Pereira
Universidade Federal de Pernambuco
Av. Prof° Moraes Rego, 1235 – Cidade Universitária, Recife – PE
deboravianapereira@gmail.com

Caroline Maria de Miranda Mota
Universidade Federal de Pernambuco
Av. Prof° Moraes Rego, 1235 – Cidade Universitária, Recife – PE
carol3m@gmail.com

RESUMO

Este estudo apresenta um modelo de decisão multicritério integrado com um sistema de informação geográfica, a fim de classificar áreas vulneráveis. Para este estudo, analisou-se o bairro de Boa Viagem, localizado na cidade de Recife (Pernambuco, Brasil). Aplicou-se o método multicritério *Dominance-based Rough Set Approach* para classificar os 168 setores censitários, considerando fatores como renda, desigualdade, educação, densidade demográfica e desemprego. Além disso, o método foi integrado com um ambiente espacial; com a finalidade de facilitar ao tomador de decisão a aplicação do método e a visualização dos resultados. O método mostrou que 16,07% dos setores censitários podem ser classificados como de baixa vulnerabilidade, 57,14% como vulnerabilidade média e 26,79% como alta vulnerabilidade. Esta classificação pode ser uma informação útil para a alocação de esforços públicos interessados em reduzir a violência.

PALAVRAS CHAVE. Abordagem multicritério, *Dominance-based Rough Set Approach*, Segurança pública.
Tópico do artigo: Apoio à Decisão Multicritério; PO na Administração Pública.

ABSTRACT

This study presents a multiple criteria decision model, integrated with a geographic information system, in order to classify the most vulnerable areas. For this study, we analyzed the neighborhood of Boa Viagem, located in the city of Recife (Pernambuco, Brazil). We applied the multiple criteria Dominance-based Rough Set Approach in order to classify 168 census tracts, considering factors as income, inequality, education, demographic density, and unemployment. Moreover, this method was integrated with a spatial environment; with the purpose of facilitate for the decision maker the method application and the visualization of results. The method showed that 16,07% of the census tracts may be classified as low vulnerability, 57,14% as medium vulnerability, and 26,79% as high vulnerability. This classification can be an useful information toward the allocation of public efforts concerned in reducing violence.

KEYWORDS. Multicriteria approach. Dominance-based Rough Set Approach. Public Security
Paper topics: Multicriteria Decision Support; OR in public management.

1. Introdução

A questão da violência é algo frequentemente discutido na sociedade atual. Nos últimos anos, muitos estudos que tratam sobre criminalidade têm sido conduzidos (Andresen 2014). O fenômeno da violência também pode ser entendido através de alguns fatores, tais como renda, educação, desigualdade social e densidade populacional. Esses fatores estão relacionados a algumas teorias (teoria da desorganização social, por exemplo), que nos dão insights para entender esse fenômeno do crime, em um contexto social particular (Andresen 2014; Andresen 2006).

Por outro lado, investigar esse problema exclusivamente através de estruturas teóricas pode gerar insatisfação entre algumas das partes interessadas (tais como governo, polícia e a sociedade em geral). Portanto, alguns autores apresentam trabalhos práticos com aplicações baseadas em tratamentos estatísticos para sugerir que áreas podem ser mais ou menos perigosas, ou quais fatores que contribuem com a violência (Anselin et al. 2000, Gawryszewski et al. 2005; Lima et al. 2005; Sachsida et al. 2007; Ceccato et al. 2007; Araújo et al. 2010; Loureiro e Silva 2012, Sauret et al. 2012, Andresen 2013; Menezes et al. 2013; Beato et al. 2014; Kim et al. 2014; Pereira et al. 2015).

Estudos recentes têm usado Sistemas de Informação Geográfica (SIG) com o intuito de avaliar o crime em um ambiente espacial (Kuo et al. 2013; Mohler 2014; Weisburd e Telep, 2014; Braga et al. 2014). Tais estudos incorporam a dimensão espacial às suas análises, tornando o estudo mais completo e de melhor visualização. Como consequência, a junção de conceitos de criminalidade e ambiente SIG podem gerar técnicas que podem ser utilizadas no combate à violência.

No entanto, (Gurgel e Mota 2013) apresentam um estudo diferente que envolve fatores relacionados com a violência, ambiente SIG e modelos de decisão. Este trabalho usa apoio multicritério à decisão (AMD) para ranquear os locais mais propensos à violência considerando vários critérios simultaneamente. Então, essa priorização pode ser usada para estabelecer estratégias para combater a violência.

Diante da intenção de continuar com essa integração, esse trabalho tem o propósito de apresentar um modelo envolvendo técnicas de SIG e AMD, dentro do contexto da segurança pública. O objetivo do modelo é classificar áreas de acordo com vulnerabilidade a homicídios. Uma aplicação foi feita em um bairro da cidade do Recife (Pernambuco, Brasil). O resultado mostra que 26,79% das áreas do bairro de Boa Viagem podem ser classificadas como nível de vulnerabilidade alto 57,14% como médio, e 16,07% como baixo.

O restante deste artigo está organizado da seguinte maneira: seção 2 apresenta uma breve revisão de MCDA e explica o modelo utilizado (Dominance-based Rough Set Approach). Seção 3 mostra a metodologia do trabalho. A quarta seção traz detalhes sobre a aplicação, enquanto a seção 5 oferece os resultados e a discussão. Finalmente, as considerações finais são feitas na seção 6.

2. Revisão Teórica

2.1 Apoio à Decisão Multicritério

O objetivo principal do apoio multicritério à decisão (AMD) é ajudar um decisor em escolher, classificar ou ordenar duas ou mais alternativas, que são avaliadas por um conjunto finito de critérios (Roy 1996; Slowinksi et al. 2012). A partir de um conjunto finito e não vazio de n alternativas, $A = \{a_1, a_2, \dots, a_n\}$, o decisor pode querer uma recomendação final que envolva: i) um subconjunto das melhores alternativas; ii) alocação das alternativas em classes ordenadas; iii) ranqueamento das alternativas (Roy 1996). A fim de obter essas recomendações, é necessário agregar as preferências do decisor.

Na literatura, muitos métodos AMD são propostos para realizar essa agregação (Roy 1996; Keeney e Raiffa 1993; Edwards e Barron 1994; Dias e Clímaco 2000; Figueira et al. 2009;

Greco et al. 1999; Greco et al. 2002). Também se pode encontrar na literatura métodos diferentes para classificar alternativas (Greco et al. 2002; Belton e Stewart, 2002; Almeida-Dias et al. 2010).

Outro ponto importante é a presença de trabalhos que envolvem tanto AMD como SIG, em várias áreas de conhecimento (Chen et al. 2013; Gbaine et al. 2013; Gomes e Lins 2013; Krois e Schulte 2014). Nesses estudos, são apresentadas aplicações reais que integram vários dos métodos multicritérios existentes e o ambiente espacial, demonstrando a viabilidade das duas ferramentas.

2.2 Dominance-based Rough Set Approach

O método *Dominance-based Rough Set Approach* (DRSA) tem a intenção de gerar uma classificação do conjunto de alternativas, baseado em exemplos de preferência escolhidos previamente pelo decisor (Figueira et al. 2009; Greco et al. 1999; Greco et al. 2002). Esses exemplos devem pertencer a um conjunto de alternativas (reais ou fictícias), influenciada por todos os critérios. A classificação final é dada por um grupo de regras de decisão do tipo "se... então...", conduzindo a uma classe Cl_t.

Notações utilizadas:

- $A = \{a_1, a_2, \dots, a_n\}$ é conjunto finito de alternativas;
- $A^* = \{a^*, \dots, b^*, \dots\}$ são as alternativas de referências, com $A^* \subseteq A$
- $C = \{c_1, c_2, \dots, c_m\}$ é conjunto finito de critérios de avaliação;
- $c_m(a_n^*)$ $\forall a_n^* \in A$é a avaliação de cada alternativa de referência com relação a um dado critério;
- $c_m(a_1^*) \succ c_m(a_2^*)$ é a relação monotônica estabelecida para avaliar duas alternativas com relação ao mesmo critério. Além disso, existem dois tipos de critério: critério custo (quanto menor melhor) e critério ganho (quanto maior melhor).
- $Cl = \{Cl_t, t \in T\}$ com $T=\{1,\dots,n\}$ são as classes de decisão previamente definidas pelo decisor. Cada alternativa de referência deve pertencer somente a uma classe.

A relação de dominância, também precisa ser definida conforme a proposta do DRSA. Para o subconjunto de critérios, a relação de dominância (D_P) é tal que: se para $P \in C$ e alternativa a_1^* domina a_2^* no espaço de critérios de condição (denotado por $a_1^* D_p a_2^*$) if $a_1^* \gtrsim a_2^*$ $\forall c \in P$. Assumindo sem perda de generalidade que o domínio dos critérios são numéricos e possuem preferência crescente (ganho) ou decrescente (custo). Também $a_1^* D_p a_2^*$ é equivalente a $a_1^* \geq a_2^*$ $\forall c \in P, P \subseteq C$. Esta mesma definição é mantida para o espaço das classes de decisão (Greco et al. 2012).

Após a definição da relação da dominância, são estabelecidos os conjuntos que são dominantes sobre uma alternativa e os conjuntos que são dominados por uma alternativa:

- As alternativas que dominam a_1^* com relação P (1):

$$D_p^+(a_1^*) = \{a_2^* \in A^* : a_2^* D_p a_1^*\} \tag{1}$$

- As alternativas que são dominadas por a_1^* com relação P (2):

$$D_p^-(a_1^*) = \{a_2^* \in A^* : a_1^* D_p a_2^*\} \tag{2}$$

Após essas definições, as alternativas são incluídas nas chamadas aproximações P-superior e P-inferior da união das classes. Sendo que uma alternativa pode pertencer no máximo a uma classe ($Cl_t^{\leq}$) ou pelo menos a uma classe ($Cl_t^{\geq}$):

- A aproximação P-superior e P-inferior de $Cl_t^{\geq}$ (3) e (4):

$$\bar{P}(Cl_t^{\geq}) = \{a_1^* \in A^* : D_P^-(a_1^*) \cap Cl_t^{\geq} \neq \emptyset\} \tag{3}$$

$$\underline{P}(Cl_t^{\geq}) = \{a_1^* \in A^* : D_P^+(a_1^*) \subseteq Cl_t^{\geq}\} \tag{4}$$

- A aproximação P-inferior e P-superior de $Cl_t^{\leq}$ (5) e (6):

$$\bar{P}(Cl_t^{\leq}) = \{a_1^* \in A^*: D_P^+(a_1^*) \cap Cl_t^{\leq} \neq \emptyset\} \quad (5)$$

$$\underline{P}(Cl_t^{\leq}) = \{a_1^* \in A^*: D_P^-(a_1^*) \subseteq Cl_t^{\leq}\} \quad (6)$$

Essas definições contém o critério que é mais importante na geração dos rankings finais, que são determinados pelas funções:

$$Bn_P(Cl_t^{\geq}) = \bar{P}(Cl_t^{\geq}) - \underline{P}(Cl_t^{\geq}) \quad (7)$$

$$Bn_P(Cl_t^{\leq}) = \bar{P}(Cl_t^{\leq}) - \underline{P}(Cl_t^{\leq}) \quad (8)$$

A qualidade da partição das classes para um conjunto P é medida conforme a seguinte equação (9):

$$\gamma_P(Cl) = \frac{card(A^* - (\cup_{t \in T} Bn_P(Cl_t^{\leq})))}{card(A^*)} \quad (9)$$

Essa razão expressa todas alternativas de referência corretamente classificadas em relação a todos os exemplos de referência que foram usados.

Finalmente, o método DRSA induz a criação das regras de decisão usando o algoritmo DOMLEM. As regras são divididas em duas partes. A primeira, são as condições (SE) assumidas em cada critério e a segunda, é a parte de decisão (ENTÃO) com respeito às decisões. Três tipos de regras são consideradas. Neste estudo foram usadas as regras do tipo "*certain*", geradas par a aproximação P-inferior. Mais detalhes podem ser consultados em (Greco et al. 2012).

3. Metodologia

O desenvolvimento desse modelo pode ser dividido em quatro passos. A Figura 1 mostra o resumo dessas quatro etapas. O primeiro passo consiste na estruturação do problema, envolvendo: demarcação da área de aplicação, definição das alternativas, determinação dos critérios e definição das classes. Em seguida, todos esses dados devem ser convertidos em um mapa, para que o ambiente espacial possa ser explorado.

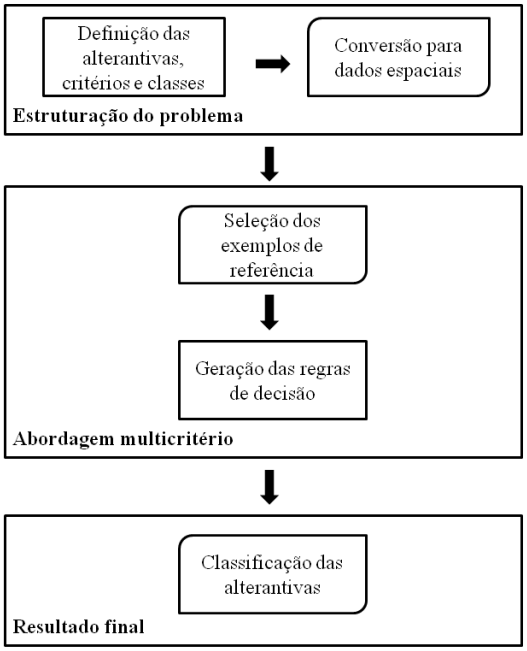

Figura 1. Fluxograma da construção do modelo

A segunda fase está relacionada à abordagem multicritério. Aqui, primeiramente o decisor precisa escolher os exemplos de referência e alocá-los a uma das classes. Em seguida, os

dados são exportados para o programa jMAF, onde as aproximações das classes serão obtidas. Depois, a qualidade das aproximações será calculada e as regras de decisão serão criadas. Por fim, as regras de decisão são usadas para classificar as alternativas.

A terceira e última fase envolve a recomendação final do modelo. O resultado final do DRSA (classificação) é transferido para o SIG (ArcGIS) e assim o decisor pode visualizar a recomendação do modelo.

É importante mencionar que as variáveis sociais, econômicas e demográficas usadas nesse trabalho foram extraídas do censo demográfico de 2010 (IBGE 2015). E ainda, os softwares utilizados nesse estudo foram ArcGIS, MATLAB, and jMAF.

4. Aplicação do Modelo

4.1 Área de Aplicação

Este modelo foi aplicado em um bairro da cidade do Recife, Boa Viagem. Recife é a capital do estado de Pernambuco, estado do Nordeste brasileiro. O bairro de Boa Viagem é bastante conhecido, visto que é um dos bairros que acompanha a orla litorânea de Recife, na zona sul da cidade. Esse bairro é heterogêneo em termos de ocupação do solo, já que é composto tanto por áreas residenciais como comerciais. Boa Viagem concentra um grande número de hotéis e atrações turísticas da cidade, além de ser uma área marcada também pelos pontos comerciais (shoppings, galerias, restaurantes, etc). Ainda, o bairro é habitado por pessoas com poderes aquisitivos distintos: em Boa Viagem pode-se encontrar torres residenciais de alto luxo, assim como algumas favelas.

4.2 Definição de Alternativas, Critérios e Classes

Nesta aplicação, considerou-se como alternativas os 168 setores censitários de Boa Viagem. O bairro de Boa Viagem é composto por 168 sub-regiões, chamadas de setores censitários (SC). Essa divisão é feita pelo IBGE e é a menor unidade administrativa que pode-se analisar. Vários fatores sociais, econômicos e demográficos são coletados para cada SC pelo IBGE a cada dez anos, através do censo. A Figura 2 mostra a localização geográfica do bairro de Boa Viagem.

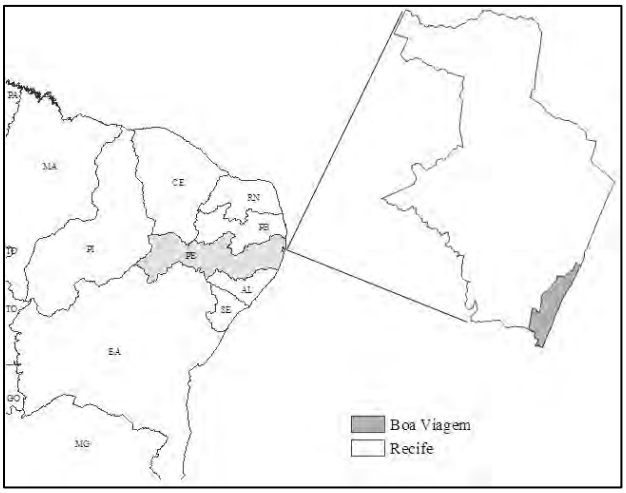

Figura 2. Localização do bairro de Boa Viagem

Para a definição dos critérios, optou-se por fazer uma revisão da literatura a fim de investigar quais fatores são apontados como estatisticamente relacionados com a violência. Procurou-se, portanto, trabalhos realizados no Brasil que analisassem a relação de variáveis sociais, econômicas e demográficas com homicídios. Vários trabalhos envolvendo esse tipo de

estudo foram encontrados (Anselin et al. 2000, Gawryszewski et al. 2005; Lima et al. 2005; Sachsida et al. 2007; Ceccato et al. 2007; Araújo et al. 2010; Loureiro e Silva 2012, Sauret et al. 2012, Andresen 2013; Menezes et al. 2013; Beato et al. 2014; Kim et al. 2014; Pereira et al. 2015).

Diante de tais estudos, decidiu-se adotar cinco fatores para classificar as áreas de Boa Viagem em relação à vulnerabilidade a homicídios. Os fatores foram escolhidos de acordo com a relevância nos trabalhos citados anteriormente. Posteriormente, buscou-se variáveis levantadas pelo censo demográfico do IBGE que pudessem representar tais fatores. Sendo assim, os fatores considerados no modelo como critérios são:

- Densidade demográfica: mensurado a partir do número de residentes dividido pela área;
- Educação: mensurado a partir do percentual de pessoas acima de 5 anos alfabetizadas;
- Renda: mensurado a partir do logaritmo da renda média dos chefes de família;
- Desigualdade: mensurado a partir do logaritmo do desvio padrão da renda média dos chefes de família; e
- Desemprego: mensurado pelo percentual das pessoas sem renda.

A Tabela 1 mostra a estatística descritiva para os critérios utilizados nesse modelo: média, desvio padrão, valor máximo e valor mínimo.

Tabela 1. Estatística descritiva dos critérios

Critério	Valo mínimo	Valor máximo	Média	Desvio padrão
Densidade	1029,45	91984,60	25744,67	15824,21
Educação	69,80	99,38	92,12	5,14
Renda	6,02	9,81	8,27	0,68
Desigualdade	11,62	21,82	16,71	1,53
Desemprego	15,62	84,23	27,51	6,72

Finalmente, foram estabelecidas as classes ordenadas para classificação das alternativas. Definiu-se que três classes seriam suficientes para medir a vulnerabilidade das áreas de Boa Viagem: vulnerabilidade alta (1), média (2) e baixa (3).

5. Resultados e Discussão

Finalmente, foram retirados 15 exemplos de referência e os mesmos foram classificados, como mostra a Tabela 2. Para os exemplos de referência houve uma qualidade geral de 0,989 e para as classes: $Cl_1^{\leq}, Cl_2^{\geq}, Cl_3^{\leq} = 0{,}974$. Portanto, com estes valores próximos a 1, observa-se uma adequação dos exemplos de referências e uma classificação satisfatória das demais alternativas.

Tabela 2. Exemplos de referência

Exemplos	Densidade	Educação	Renda	Desigualdade	Desemprego	Classe
1	28098,37	80,33	7,18	15,30	36,90	1
2	11701,65	78,37	7,30	15,56	29,24	1
3	16834,84	72,97	6,75	14,71	32,06	1
4	33946,48	76,22	6,65	14,25	26,59	1
5	47044,25	79,04	6,40	13,30	30,72	1
6	9750,34	90,97	8,46	16,51	20,23	1
7	15172,70	91,01	8,83	17,29	25,83	1
8	11358,79	94,80	8,81	18,30	27,42	2
9	13969,12	95,77	9,18	19,21	21,51	2

Exemplos	Densidade	Educação	Renda	Desigualdade	Desemprego	Classe
10	23925,30	94,89	9,03	19,86	22,17	2
11	18939,67	91,76	8,80	17,24	27,39	2
12	30187,43	94,21	8,12	16,46	22,83	2
13	24305,64	95,59	8,28	16,38	23,80	3
14	11919,15	95,72	8,93	18,67	21,62	3
15	7823,25	95,74	8,41	16,83	28,15	3

Através do algoritmo DOMLEM, foram geradas 10 regras do tipo "*certain*" para Cl aproximação inferior. Todas as regras foram usadas para classificar o bairro de Boa Viagem. As regras de decisão para essa aplicação podem ser consultadas na Tabela 3, assim como o número de exemplos de referência que suportam cada regra.

Tabela 3. Regras de decisão

Regras	Descrição da regra	Classe	Número de exemplos
Regra 1	Se (Renda≥ 8,72), então...	Pelo menos 3	4
Regra 2	Se (Densidade≤17980,02) & (Desigualdade≤15,78), então...	Pelo menos 3	2
Regra 3	Se (Renda≥8,45), então...	Pelo menos 2	6
Regra 4	Se (Desemprego≤23,55), então...	Pelo menos 2	5
Regra 5	Se (Densidade≤17980,02) & (Desigualdade≤16,60), então...	Pelo menos 2	5
Regra 6	Se (Renda≤7,56) & (Desigualdade≤16,15), então...	Pelo menos 2	4
Regra 7	Se (Renda≤7,18), então...	No máximo 1	2
Regra 8	Se (Densidade≥19764,02) & (Desemprego≥30,55), então...	Pelo menos 1	2
Regra 9	Se (Densidade≥24305,64) & (Renda≤8,28), então...	Pelo menos 1	1
Regra 10	Se (Desigualdade≥16,83) & (Desemprego≥28,14), então...	No máximo 1	1
Regra 11	Se (Educação≤80,33), então...	No máximo 2	3
Regra 12	Se (Renda≤8,71) & (Desigualdade≥15,96), então...	No máximo 2	9

Essas regras foram aplicadas e obteve-se a classificação dos setores censitários nos três níveis de vulnerabilidade. Esse resultado foi exportado para o ArcGIS e assim criou-se um mapa com a classificação, conforme a Figura 3. Os locais mais escuros são aqueles mais vulneráveis à violência. Além disso, a Tabela 4 mostra o número de áreas alocadas a cada uma das classes.

Figura 3. Áreas de vulnerabilidade de Boa Viagem, de acordo com a abordagem DRSA

Tabela 4. Número de setores censitários em cada classe

Classe	Setores censitários
Nível de vulnerabilidade alto	45
Nível de vulnerabilidade moderado	96
Nível de vulnerabilidade baixo	27

O resultado do método classificou 16,07% dos setores censitários como de baixa vulnerabilidade, 57,14% como vulnerabilidade média e 26,79% como alta vulnerabilidade. Pode-se perceber, portanto, que mais da metade das áreas são consideradas como de vulnerabilidade moderada e que quase 27% dos locais são aqueles que requerem maior atenção e cuidado. Além disso, através da Figura 3, pode-se observar que existe uma certa aglomeração dos setores censitários com classes iguais. Sendo assim, pode-se dizer que os valores relacionados aos critérios são similares. Essa assertiva fica evidente, pois as regras atuam como limitadores dos valores com relação a cada critério. Então, as regras condicionais limitam as alternativas, conduzindo-as para as mesmas classes.

A Figura 3 mostra que as áreas mais vulneráveis se concentram principalmente em três regiões de Boa Viagem: na parte norte, central e sudoeste – e com poucas áreas espalhadas entre essas últimas duas. Ao todo, 45 alternativas foram classificadas como de alto nível de vulnerabilidade. Esse tipo de classificação é importante porque há uma escassez de recursos e por isso deve haver algum tipo de priorização para alocar os recursos públicos. As áreas mais vulneráveis demandam maior atenção das políticas públicas, visto a situação desfavorável de sua comunidade. As áreas classificadas neste nível apresentam geralmente alta densidade populacional, baixa renda, grande desigualdade, baixa educação e grande índice de desemprego.

Nesse sentido, políticas públicas podem ser implantadas nesses locais a fim de reduzir a vulnerabilidade existente e, consequentemente, impactar na redução da violência. Por exemplo, muitas das áreas mais vulneráveis apresentam um baixo nível de educação, então políticas públicas podem ser tomadas no sentido de implantar novas escolas ou fortalecer o ensino das já existentes. O bairro de Boa Viagem é conhecido pelas discrepantes características sociais e econômicas, havendo um grande contraste entre edifícios luxuosos e favelas. Algumas medidas podem ser tomadas, portanto, para suavizar essas diferenças.

É importante salientar que o resultado desse modelo pode ser utilizado na tomada de decisão pública, para definição de alocação de recursos. A utilização desse modelo pode contribuir para uma decisão mais estruturada e transparente, além de considerar vários critérios ao mesmo tempo. Sendo assim, seria interessante adotar um planejamento pautado em diversos elementos (critérios) que possam ser usados para auxiliar na priorização e escolha de recursos que beneficiem a sociedade.

O DRSA foi escolhido por não exigir grande esforço cognitivo por parte do decisor. O método apenas requer uma escolha holística dos exemplos de referência, eliminando a necessidade de limiares de preferência / indiferença e pesos para os critérios. Portanto, o decisor pode se sentir mais confortável no momento de expressar suas escolhas sobre o problema. Ressalta-se que o método não é uma aplicação puramente matemática, visto que as preferências do gestor são importantes no seu desenvolvimento. Inclusive, outras metodologias multicritério podem ser utilizadas, a fim de suportar preferências de vários decisores.

Ainda, é importante destacar que o resultado do modelo foi exportado para um sistema de informações geográficas. Isso foi feito com o intuito de auxiliar o entendimento do resultado do método. A partir de um mapa, fica mais claro que áreas são mais problemáticas, assim como qual a sua distribuição em todo o espaço. Além disso, o esforço requerido do agente de decisão é diferenciado, pois na presente proposta ele pode utilizar exemplos reais que estão contidos no conjunto das alternativas do problema.

Foi feita uma comparação do resultado do modelo com o número de homicídios ocorrido em Boa Viagem entre os anos 2008 e 2013. A Figura 4 mostra a comparação entre as áreas de vulnerabilidade e os homicídios em Boa Viagem. Os mapas sugerem que os locais classificados com alta vulnerabilidade são similares a aqueles que apresentam densidade de homicídios mais acentuada. Analisando o mapa de homicídios, pode-se perceber uma maior concentração de ocorrências na parte norte e na área central. Portanto, pode-se dizer que o modelo proposto é útil na identificação de áreas mais suscetíveis a homicídios.

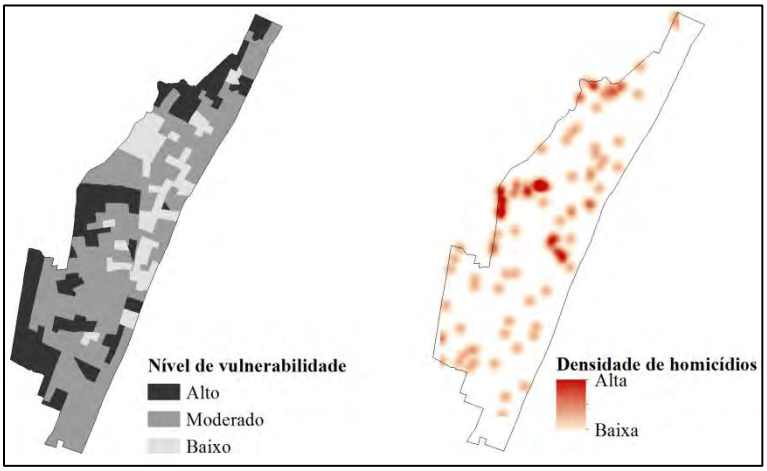

Figura 4. Comparação das áreas de vulnerabilidade e os homicídios em Boa Viagem

Visto que as áreas com maior propensão a homicídios podem ser identificadas, algumas medidas de fortalecimento da comunidade podem ser tomadas nesses locais, a fim de reduzir a violência. Cabe ressaltar que tais ações dificilmente trarão um efeito ao curto prazo, mas elas podem oferecer consequências sólidas no longo prazo. Medidas para transformar a situação econômica e social da comunidade são importantes porque podem influenciar intimamente na vida dos indivíduos, tornando as atividades ilícitas menos atrativas. No entanto, não estamos dizendo que o patrulhamento policial não é importante. Ele é essencial para combater a violência nas ruas. Porém, o esforço policial pode ser combinado com políticas públicas, a fim de mitigar a violência de um modo geral.

6. Conclusões

Este estudo se propôs a classificar setores censitários de um bairro da cidade do Recife na tentativa de avaliar os níveis de vulnerabilidade a homicídios. Essa classificação foi realizada com a integração de um método multicritério (DRSA) e um sistema de informação geográfica, considerando critérios como renda, desigualdade, educação, densidade populacional e desemprego.

Os resultados mostraram que 26,79% das áreas do bairro de Boa Viagem podem ser classificadas como vulnerabilidade alta, 57,14% como moderada, e 16,07% como baixa. Pode-se dizer que a classificação é eficaz na identificação de áreas mais propensas a homicídios, pois as áreas destacadas como mais vulneráveis são similares a aquelas onde aconteceram mais homicídios entre 2008 e 2013.

A classificação dos setores censitários pode ser útil para a alocação de políticas públicas, visto que evidencia as áreas em situação mais desfavorecida. Portanto, medidas de fortalecimento podem ser tomadas nessas comunidades, causando, consequentemente, uma redução da violência no longo prazo.

Constata-se que o método DRSA é adequado para esse contexto porque é de fácil aplicação para o decisor, visto que não requer um esforço cognitivo significativo por parte dele, como definição de limiares e pesos. O DRSA ainda foi integrado ao ambiente SIG, numa tentativa exitosa de elucidar a leitura dos resultados. Para estudos futuros pretende-se modelar as preferências de mais decisores / gestores para o problema.

Referências

Almeida-Dias, J., Figueira, J. R. e Roy, B. (2010). Electre Tri-C: A multiple criteria sorting method based on characteristic reference actions. *European Journal of Operational Research*, 204, 565-580.

Andresen, M. A. (2006). Crime measures and the spatial analysis of criminal activity. *British Journal of Criminology*, 46, 258-285.

Andresen, M. A. (2013). Unemployment, business cycles, crime, and the Canadian provinces. *Journal of Criminal Justice*, 41, 220-227.

Andresen, M. A. (2014). Environmental Criminology: evolution, theory and practice. Routledge, Nova York.

Anselin, L., Cohen, J., Cook, D., Goor, W. e Tita, G. (2000). Spatial analyses of crime. Criminal Justice: measurement and analysis of crime and justice. National Institute of Justice.

Araújo, E. M., Costa, M. C. N., Oliveira, N. F., Santana, F. S., Barreto, M. L., Hogan, V. e Araújo, T. M. (2010). Spatial distribution of mortality by homicide and social inequalities according to race/ skin color in an intra-urban Brazilian space. *Revista Brasileira de Epidemiologia*, 13, 549–560.

Beato, C. e Silveira, A. M. (2014). Effectiveness and evaluation of crime prevention programs in Minas Gerais. *Stability: International Journal of Security & Development*, 3, 1-18.

Belton, V. e Stewart, T. J. (2002). Multiple Criteria Decision Analysis. Kluwer Academic Publishers, Boston.

Braga, A. A., Papachristos, A. V. e Hureau, D. M. (2014). The effects of hot spots policing on crime: an updated systematic review and meta-analysis. *Justice Quarterly*, 31, 633-663.

Ceccato, V., Haining, R. e Kahn, T. (2007). The geography of homicide in São Paulo, Brazil. *Environment and Planning A*, 39, 1632–1653.

Chen, Y., Yu, J. e Khan, S. (2013). The spatial framework for weight sensitivity analysis in AHP-based multi-criteria decision-making. *Environmental Modelling & Software*, 48, 129-140.

Dias, L. C. e Clímaco, J. N. (2000). Additive aggregation with variable interdependent parameters: the VIP analysis software. *Journal of the Operational Research Society*, 51, 1070-1081.

Edwards, W. e Barron, F. H. (1994). SMARTS and SMARTER: improved simple method of multiattribute utility measurement. *Organizational Behavior and Human Decision Process*, 60, 306-325.

Figueira, J. R., Greco, S. e Slowinksi, R. (2009). Building a set of additive value functions representing a reference preorder and intensities of preference: GRIP method. *European Journal of Operational Research*, 195, 460-486.

Gawryszewski, V. P. e Costa, L. S. (2005). Social inequality and homicide rates in São Paulo city, Brazil. *Revista de Saúde Pública*, 39, 191–197.

Gbanie, S. P., Tengbe, P. B., Momoh, J. S., Medo, J. e Kabba, V. T. S. (2013). Modelling landfill location using Geographical Information Systems (GIS) and Multi-criteria Decision Analysis (MCDA): case study Bo, Southern Sierra Leone. *Applied Geography*, 36, 3-12.

Gomes, E. G. e Lins, M. P. E. (2002). Integrating geographical information systems and multi-criteria methods: a case study. In *Annals of Operations Research*, 116, 243-269.

Greco, S., Matarazzo, B. e Slowinkski, R. (1999). Rough approximation of a preference relation by dominance relation. *European Journal of Operational Research*, 117, 63–83.

Greco, S., Matarazzo, B. e Slowinski, R. (2002). Rough sets methodology for sorting problems in presence of multiple attributes and criteria. *European Journal of Operational Research*, 138, 247–259.

Gurgel, A. M. e Mota, C. M. M. (2013). Multicriteria priorization model to support public safety planning. *Operational Research*, 33, 251-267.

Instituto Brasileiro de Geografia e Estatística (IBGE). (2015). Censo demográfico 2010 - Resultados do universo. http://censo2010.ibge.gov.br/. Acessado em 04/02/2015.

Keeney, R. L. e Raiffa, H. (1993). Decision with multiple objectives: preferences and value trade-offs. Cambridge University Press, Cambridge.

Kim, B., Pratt, T. C. e Wallace, D. (2014). Adverse neighborhood conditions and sanction risk perceptions: using SEM to examine direct and indirect effects. *Journal of Quantitative Criminology*, 30, 505-526.

Krois, J. e Schulte, A. (2014). GIS-based multi-criteria evaluation to identify potential sites for soil and water conservation techniques in the Ronquillo watershed. *Applied Geography*, 51, 131-142.

Kuo, P., Lord, D. e Walden, T. D. (2013). Using geographical information systems to organize police patrol routes effectively by grouping hotspots of crash and crime data. *Journal of Transport Geography*, 30, 138-148.

Lima, M. L. C. de, Ximenes, R. A. A., Souza, E. R., Luna, C. F. e Albuquerque, M. F. P. M. (2005). Spatial analysis of socioeconomic determinants of homicide in Brazil. *Revista de Saúde Pública*, 39, 176–182.

Loureiro, P. R. A. e Silva, E. C. D. (2012). What causes intentional homicide? *Journal of International Development*, 24, 287–303.

Menezes, T., Silveira-Neto, R., Monteiro, C. e Ratton, J. L. (2013). Spatial correlation between homicide rates and inequality: Evidence from urban neighborhoods. *Economics Letters*, 120(1): 97–99.

Mohler, G. (2014). Marked point process hotspot maps for homicide and gun crime prediction in Chicago. *International Journal of Forecasting*, 30, 491-497.

Pereira, D. V. S., Mota, C. M. M. e Andresen, M. A. (2015). Social Disorganization and Homicide in Recife, Brazil. *International Journal of Offender Therapy and Comparative Criminology*, 1-23, no prelo.

Roy, B. (1996). Multicriteria methodology for decision aiding. Kluver Academic Publishers, Netherlands.

Sachsida, A., Mendonça, M. J. C., Loureiro, P. R. A. e Gutierrez, M. B. S. (2007). Inequality and criminality revisited: Further evidence from Brazil. *Empirical Economics*, 39, 93–109.

Sauret, G., Tiné, M. e Farias, E. (2012). Correlacionando violência e indicadores sociais no Recife: qual a melhor unidade espacial de análise? em Sauret, G. (ed.). In Estatísticas pela vida: A coleta e análise de informações criminais como instrumentos de enfrentamento da violência letal. Bargaço Design, Recife, 78-101.

Slowinksi, R., Greco, S. e Matarazzo, B. (2012). Rough set and rule-based multicriteria decision aiding. *Operational Research*, 32, 213-269.

Weisburd, D. e Telep, C. W. (2014). Hot spots policing: what we know and what we need to know. *Journal of Contemporary Criminal Justice*, 30, 200-220.