



Avaliação de áreas em segurança pública: uma abordagem GIS-MCDA com sensoramento remoto

Ciro José Jardim de Figueiredo

Universidade Federal de Pernambuco
Av. Profº Moraes Rego, 1235 – Cidade Universitária, Recife – PE
ciro.figueiredo@ufpe.br

Débora Viana e Sousa Pereira

Universidade de Pernambuco
Av. Sport Club do Recife, 252 - Madalena - Recife/PE
deboravianapereira@gmail.com

Caroline Maria de Miranda Mota

Universidade Federal de Pernambuco
Av. Profº Moraes Rego, 1235 – Cidade Universitária, Recife – PE
carol3m@gmail.com

RESUMO

A integração entre Apoio Multicritério a Decisão e Sistemas de Informação Geográfica vem sendo objeto de estudo há pelo menos 20 anos. As aplicações com GIS-MCDA são feitas em diferentes campos de pesquisa e, recentemente, a abordagem tem sido aplicada no planejamento de políticas de segurança pública. Esse trabalho tem o propósito de apresentar um modelo GIS-MCDA, considerando o sensoramento remoto, dentro do contexto da segurança pública. O objetivo do modelo é classificar áreas de acordo com vulnerabilidade a homicídios, considerando aspectos sociais, econômicos e demográficos. Uma aplicação foi feita em uma região da cidade do Recife (Pernambuco, Brasil), utilizando *Dominance-based Rough Set Approach*. O resultado do modelo pode ser considerado satisfatório, visto que há similaridade entre a saída do modelo proposto e o mapa de densidade de homicídios da área.

PALAVRAS CHAVE. Segurança pública, Sistemas de Informação Geográfica, Decisão Multicritério, Sensoramento Remoto, *Dominance-based Rough Set Approach*.

**Apoio à Decisão Multicritério
Administração Pública**

ABSTRACT

The integration between Multiple Criteria Decision Aid and Geographic Information Systems has been under study for at least 20 years. Applications with GIS-MCDA are done in different research fields and, recently, the approach has been applied in the planning of public security policies. This work aims to present a GIS-MCDA model, considering remote sensing, within the context of public security. The objective of the model is to classify areas according to vulnerability to homicides, considering social, economic, and demographic aspects. An application was made in a region of the city of Recife (Pernambuco, Brazil), using *Dominance-based Rough Set Approach*. The result of the model can be considered satisfactory, since there is similarity between the output of the proposed model and the density map of homicides of the area.

KEYWORDS. First Public Security, Geographic Information System, Multiple Criteria Decision Aid, Remote Sensing, *Dominance-based Rough Set Approach*.

Paper topics (indicate in order of PRIORITY the paper topic(s))

Multiple Criteria Decision Aid

Public Management

1. Introdução



A integração entre Apoio Multicritério a Decisão (*Multiple Criteria Decision Analysis*, MCDA) e Sistemas de Informação Geográfica (*Geographic Information System*, GIS) vem sendo objeto de estudo há pelo menos 20 anos (Carver, 1993; Jankowski, 1995; Malczewski, 1999). A abordagem GIS-MCDA engloba os conceitos oriundos de modelos multicritério, como definição de alternativas, avaliação inter-critério e intra-critério, uso de métodos compensatórios e não-compensatórios. Por outro lado, o GIS inclui a introdução de temas espaciais, como distância, declividade e uso do solo (Malczewski & Rinner, 2015). Portanto, são duas abordagens complementares (Chakhar & Mousseau, 2008).

Esta integração permite avaliar espacialmente as alternativas de decisão, flexibilizando a tomada de decisão sob diferentes aspectos (uso de critérios espaciais, alternativas com dimensões físicas diferentes e grande volume de dados). Incluem-se nestes aspectos, facilidade para visualizar as alternativas de decisão e menor esforço cognitivo para avaliação através dos mapas contendo as avaliações intra-critério (Jelokhani-Niaraki & Malczewski, 2014).

As aplicações com GIS-MCDA são feitas em diferentes campos de pesquisa, tais como planejamento agrícola e biodiversidade do solo (Fernández & Morales, 2016; Montgomery *et al.* 2016); avaliação de áreas com riscos para inundações (Hazarika *et al.* 2016); avaliação do risco de deslizamento (Pradhan & Kim, 2016); geração de energia sustentável (Sánchez-Lozano *et al.* 2016); e planejamento urbano (Jelokhani-Niaraki & Malczewski, 2015).

Mais recentemente, a integração entre GIS e MCDA tem sido aplicada no cenário de planejamento de políticas de segurança pública. Estes estudos procuram ordenar alternativas quanto à necessidade de ações de segurança (Gurgel e Mota 2013); identificar rotas de ações policiais (Figueiredo *et al.* 2015); e classificar locais mais vulneráveis a violência (Figueiredo & Mota, 2016). A aplicação das duas abordagens conjuntas é interessante, já que considera aspectos espaciais (como a classificação do solo, por exemplo) é um diferencial significativo que pode impactar no tratamento da segurança pública.

Esse trabalho tem o propósito de apresentar um modelo GIS-MCDA, considerando o sensoriamento remoto, dentro do contexto da segurança pública. O objetivo do modelo é classificar áreas de acordo com vulnerabilidade a homicídios. Uma aplicação foi feita em uma região da cidade do Recife (Pernambuco, Brasil), utilizando a abordagem DRSA (Dominance-based Rough Set Approach). O resultado mostra uma classificação de superfícies, com a exclusão de locais que não necessitam de avaliação, como corpos de água, aeroportos e área de vegetação intensa.

O restante deste artigo está organizado da seguinte maneira: seção 2 apresenta uma breve apresentação sobre sensoriamento remoto e sobre os conceitos do método utilizado, o DRSA. Seção 3 aborda 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 Sensoriamento remoto e GIS-MCDA

Pode-se definir sensoriamento remoto (SR) como a obtenção de informações sob determinado objeto, área ou fenômeno utilizando análise de dados que são adquiridos por um dispositivo (sensor) que não está em contato direto com o objeto, área ou fenômeno sob investigação (El Maguiri *et al.* (2016)). Estas informações podem ser em forma de dados ou imagens da superfície terrestre e podem ser interpretadas para fornecer informações úteis sobre o ambiente (Richards & Jia, 2006). Como exemplo, no presente estudo, o sensoriamento remoto pode ser caracterizado pela obtenção de imagens da cidade do Recife através de sensores de radiação eletromagnética, para coletar informações sobre o solo, que servirão de entrada para o modelo GIS-MCDA.

As imagens são adquiridas usando sensores que estão muito acima do solo. Estes sensores captam a luz visível e a radiação em outros comprimentos de onda como o infravermelho e as



micro-ondas. (Richards & Jia, 2006). Comumente, estas observações da superfície da terra são feitas utilizando os satélites. Portanto, o sensoriamento remoto é um processo interativo entre a radiação eletromagnética e o objeto-alvo.

A utilização do sensoriamento remoto com GIS-MCDA já vem sendo reportada em estudos voltados para outros segmentos de pesquisa. El Maguiri *et al.* (2016) apresentaram um estudo para identificação do local mais apropriado para instalação de aterro sanitário. Neste caso, os autores utilizaram as imagens de satélite para compor critérios como topografia do solo e declividade da região. Agarwal & Garg (2016) utilizaram a topografia derivada do sensoriamento remoto para mapear zonas com potencial hídrico. Rahman & Saha (2008) empregaram as imagens de satélite para mapear locais que possam ter padrões de cultivo agrícola para áreas propensas a inundações.

Depois que as imagens são obtidas por satélite, elas são tratadas, sendo transformadas em uma ou mais camadas que correspondem ao conjunto de critérios. A valoração das alternativas é feita pela classificação quanto ao uso do solo, por meio das ondas eletromagnéticas e, posteriormente, a camada é transformada em dado no formato raster. Esse conjunto de dados é uma única imagem composta por diferentes pontos chamados de pixel (Rahman & Saha, 2008). O pixel passa a ser considerado como a alternativa de decisão. O pixel é o termo que se refere a uma unidade dos dados da imagem digitalizada (Richards & Jia, 2006).

Geralmente, a agregação das camadas ocorre através de uma soma ponderada de cada raster com o seu respectivo valor de importância (w_k), conforme representado na Equação 1. a_{ik} é o valor do k -ésimo critério associado com a i -ésima alternativa ($k = 1, 2, \dots, n$ e $i = 1, 2, \dots, m$). A Figura 1 exemplifica a avaliação de uma estrutura raster segundo três critérios.

$$V(A_i) = \sum_{k=1}^n w_k v(a_{ik}) \quad (1)$$

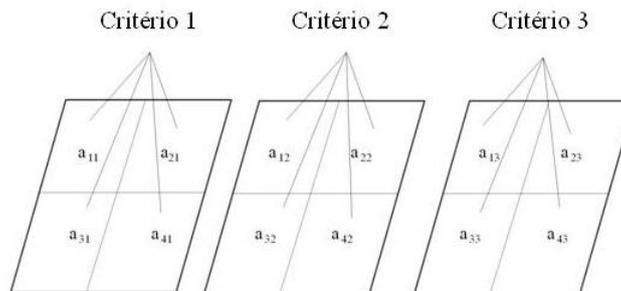


Figura 1. Processo de agregação GIS-MCDA considerando dados no formato raster.

No caso do presente estudo, a agregação das camadas acontecerá de maneira distinta, considerando regras de decisão de acordo com o modelo descrito na próxima subseção.

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 alternativas de referência escolhidas previamente pelo decisor (Figueira *et al.* 2009; Greco *et al.* 1999; Greco *et al.* 2002). Essas alternativas de referência devem pertencer a um conjunto de alternativas (reais ou fictícias), avaliadas 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 $a_1^* \succeq a_2^* \forall c \in P$. 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 de 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 (Equação 2):

$$D_P^+(a_1^*) = \{a_2^* \in A^*: a_2^* D_P a_1^*\} \quad (2)$$

- As alternativas que são dominadas por a_1^* com relação P (Equação 3):

$$D_P^-(a_1^*) = \{a_2^* \in A^*: a_1^* D_P a_2^*\} \quad (3)$$

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} (Equação 4) e (Equação 5):

$$\bar{P}(Cl_t^{\geq}) = \{a_1^* \in A^*: D_P^-(a_1^*) \cap Cl_t^{\geq} \neq \emptyset\} \quad (4)$$

$$\underline{P}(Cl_t^{\geq}) = \{a_1^* \in A^*: D_P^+(a_1^*) \subseteq Cl_t^{\geq}\} \quad (5)$$

- A aproximação P-inferior e P-superior de Cl_t^{\leq} (Equação 6) e (Equação 7):

$$\bar{P}(Cl_t^{\leq}) = \{a_1^* \in A^*: D_P^+(a_1^*) \cap Cl_t^{\leq} \neq \emptyset\} \quad (6)$$

$$\underline{P}(Cl_t^{\leq}) = \{a_1^* \in A^*: D_P^-(a_1^*) \subseteq Cl_t^{\leq}\} \quad (7)$$

Essas definições contém o critério que é mais importante na geração dos rankings finais, que são determinados pelas funções (Equação 8) e (Equação 9):

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

$$Bn_P(Cl_t^{\leq}) = \bar{P}(Cl_t^{\leq}) - \underline{P}(Cl_t^{\leq}) \quad (9)$$

A qualidade da partição das classes para um conjunto P é medida conforme a seguinte equação (Equação 10):

$$\gamma_P(Cl) = \frac{\text{card}(A^* - (\cup_{t \in T} Bn_P(Cl_t^{\leq})))}{\text{card}(A^*)} \quad (10)$$

Essa razão expressa a qualidade de todas as alternativas de referência corretamente classificadas em relação a classe de decisão.

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 considerados. Neste estudo foram usadas as regras do tipo “*certain*”, geradas para a aproximação P-inferior. Mais detalhes podem ser consultados em (Greco *et al.* 2012).

3. Metodologia proposta para avaliação de áreas de segurança



O desenvolvimento do modelo GIS-MCDA para segurança pública pode ser dividido em três etapas, conforme a Figura 2. O primeiro passo consiste na estruturação do problema, envolvendo: demarcação da área de aplicação, obtenção das imagens de satélite, definição das alternativas, determinação dos critérios e definição das classes. Em seguida, os dados são convertidos na forma raster permitindo a análise espacial. Nesta fase, também é criado o raster com as informações quanto ao uso do solo (p ex. prédios, casas, pontos comerciais) (Landsat 8). Este raster é agregado com cada critério, permitindo a obtenção dos critérios espaciais. A agregação é feita usando a combinação linear entre os rasters

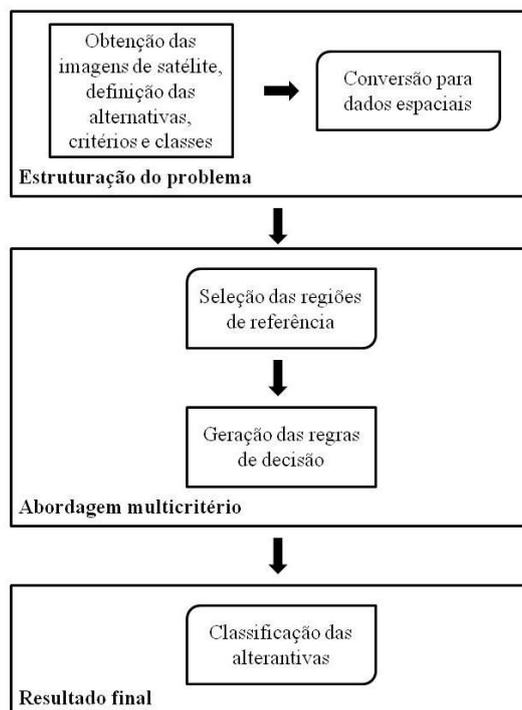


Figura 2. Fluxograma da construção do modelo.

Na segunda etapa, o decisor avalia as alternativas de referência e as aloca a uma das classes. Com base nas alocações, são extraídas as preferências do decisor e obtidas as aproximações das classes. A modelagem de preferências é feita com o uso do método DRSA. Com base nas informações e na qualidade das aproximações, são criadas as regras de decisão. Essas regras de decisão são usadas para classificar as alternativas de acordo com as classes pré-estabelecidas.-

A terceira e última fase envolve a recomendação final do modelo. O resultado final do DRSA (classificação) ao decisor para visualizar espacialmente a recomendação do modelo. Foi usada uma abordagem loose-coupling (Malczewski & Rinner, 2015). É importante mencionar que as variáveis sociais, econômicas e demográficas usadas nesse trabalho foram extraídas do censo demográfico de 2010 (IBGE 2015).

4. Aplicação do modelo

4.1 Área de aplicação

Este modelo foi aplicado em uma região da cidade do Recife, que agrega dois bairros: A e B (os nomes não são mencionados por motivos de segurança). Recife é a capital do estado de Pernambuco, estado do Nordeste brasileiro. A região escolhida é composta por bairros famosos, visto que fazem parte da orla litorânea de Recife, na zona sul da cidade. São bairros heterogêneos



em termos de ocupação do solo, já que é composto por áreas residenciais, comerciais e possui a presença de superfícies que não precisam de avaliação para o presente problema. Concentra um grande número de hotéis, áreas de lazer e atrações turísticas da cidade, além de ser uma área marcada também pelos pontos comerciais (shoppings, galerias, restaurantes, etc). Ainda, a região escolhida é habitada por pessoas com poder aquisitivo distinto: pode-se encontrar torres residenciais de alto luxo, assim como favelas. A Figura 2 mostra a localização geográfica da região de aplicação.

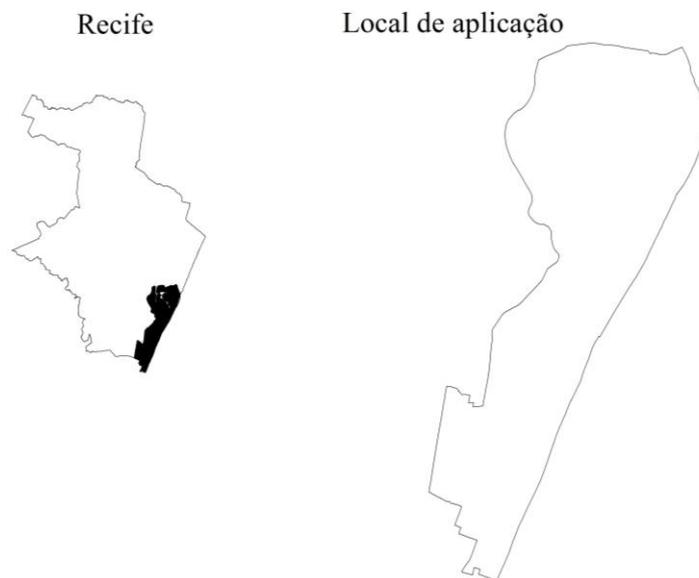


Figura 3. Localização da região de aplicação.

4.2 Definição de alternativas, critérios e classes

Nesta aplicação, considerou-se como alternativas os dados no formato raster, dividindo-se a área em pixels com dimensão de $0,25 \times 0,25$ metros. A área de aplicação foi dividida em pixels.

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 que estabelecem a relação entre fatores sociais, econômicos e demográficos e violência. Vários trabalhos envolvendo esse tipo de estudo foram encontrados (Anselin *et al.* 2000; Lima *et al.* 2005; Sachsida *et al.* 2007; Sauret *et al.* 2012, Andresen 2013; Menezes *et al.* 2013; Pereira *et al.* 2015).

Diante de tais estudos, decidiu-se adotar cinco fatores para classificar as áreas da região escolhida 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.

Os dados foram disponibilizados pelo IBGE estão apresentados em áreas administrativas chamadas de setores censitários (SC). Essa divisão 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 demográfico.

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;



- Iluminação pública: mensurado a partir do percentual de casas sem iluminação pública; e
- Residências alugadas: mensurado pelo percentual de casas alugadas.

A Tabela 1 mostra a estatística descritiva para os critérios utilizados nesse modelo: média, desvio padrão, valor máximo e valor mínimo. É importante ressaltar que estes dados, uma vez transformados no formato raster, são normalizados para um intervalo de 0 a 1

Critério	Valo mínimo	Valor máximo	Média	Desvio padrão
Densidade	231,75	91.984,60	24.674,60	16.077,02
Educação	49,65	98,55	81,08	8,56
Renda	5,70	9,80	8,03	0,80
Iluminação pública	0,00	100,00	86,46	32,89
Residências alugadas	1,29	65,38	26,20	9,80

Tabela 1. Estatística descritiva dos critérios utilizados

Foram estabelecidas as classes ordenadas para classificação das alternativas. Definiu-se um intervalo de 9 classes para medir a vulnerabilidade das áreas da região de aplicação: em um extremo há a vulnerabilidade alta (0,1) e no outro extremo a vulnerabilidade baixa (0,9). A grande vantagem de empregar os dados no formato raster é possibilitar uma análise mais sensível, pois são excluídas determinadas regiões que não precisam de avaliações, como áreas de intensa vegetação, corpos de água e aeroportos.

5. Resultados e Discussão

As regiões de referência (cada região é um pixel de 0,25×0,25 metros) foram selecionadas, resultando em um total de 200 alternativas de referência e as mesmas foram classificadas. A Tabela 2 mostra alguns pixels classificados. Para as alternativas de referência houve uma qualidade geral de 0,782 e para as classes houve uma variação de 0 a 1. A classificação usada apresentou um valor não próximo de

Tabela 2. Algumas alternativas de referência usadas na construção do problema.

Alternativas	Densidade	Educação	Renda	Iluminação pública	Residências alugadas	Classe
1	0,57	0,74	0,34	0,97	0,36	1
2	0,64	0,79	0,66	0,97	0,47	2
3	0,75	0,81	0,44	1	0,42	3
4	0,61	0,84	0,22	1	0,42	4
5	0,76	0,76	0,34	1	0,37	5
6	0,66	0,38	0,22	0,97	0,29	6
7	0,53	0,72	0,13	0,97	0,29	7
8	0,58	0,85	0,26	1	0,83	8
9	0,58	0,51	0,13	1	21,51	9

Foram geradas 20 regras do tipo “*certain*” para *Cl* aproximação inferior. Todas as regras foram usadas para classificar região. Algumas das regras de decisão para essa aplicação podem ser consultadas na Tabela 3, assim como o número de alternativas de referência que suportam cada regra.

Tabela 3. Regras de decisão.

Regras	Descrição da regra	Classe	Número de alternativas
---------------	---------------------------	---------------	-------------------------------



Regra 1	Se (Renda \leq 0,57) & (Residências alugadas \geq 0,36) então...	Pelo menos 1	21
Regra 2	Se (Ilumin_Publ \leq 0,97) & (Resid_alug \geq 0,47), então...	Pelo menos 2	22
Regra 3	Se (Ilumin_Publ \leq 0,97) & (Resid_alug \geq 0,0,36), então...	Pelo menos 6	35
Regra 4	Se (Ilum_Publ \leq 0,97), então...	Pelo menos 7	14
Regra 5	Se (Renda \leq 0,58), então...	Pelo menos 8	24
Regra 6	Se (Literacy \geq 0,85), então...	Pelo menos 8	27
Regra 7	Se (Resid_alug \leq 0,29), então...	No máximo 8	28
Regra 8	Se (Renda \geq 0,66) & (Resid_alug \leq 0,37), então...	No máximo 7	29
Regra 9	Se (Renda \geq 0,76), então...	No máximo 6	30
Regra 10	Se (Literacy \geq 0,84), então...	No máximo 5	31
Regra 11	Se (Ilum_Publ=1), então...	No máximo 4	22
Regra 12	Se (Renda \geq 0,66), então...	No máximo 2	21
Regra 13	Se (Renda \geq 0,58), então...	No máximo 2	26

Essas regras foram aplicadas e obteve-se a classificação para a região. Foram usadas regras apenas do tipo *certain* para manter uma classificação única das alternativas. Como era esperado, nem todos os pixels foram classificados com pelo menos uma das 9 faixas de vulnerabilidade que foram adotadas. Isso ocorreu em virtude do uso do sensoriamento remoto, que exclui da classificação áreas como manguezais e parques. A Figura 4 mostra a classificação da área em relação à vulnerabilidade a homicídios – os locais mais escuros são aqueles mais vulneráveis.

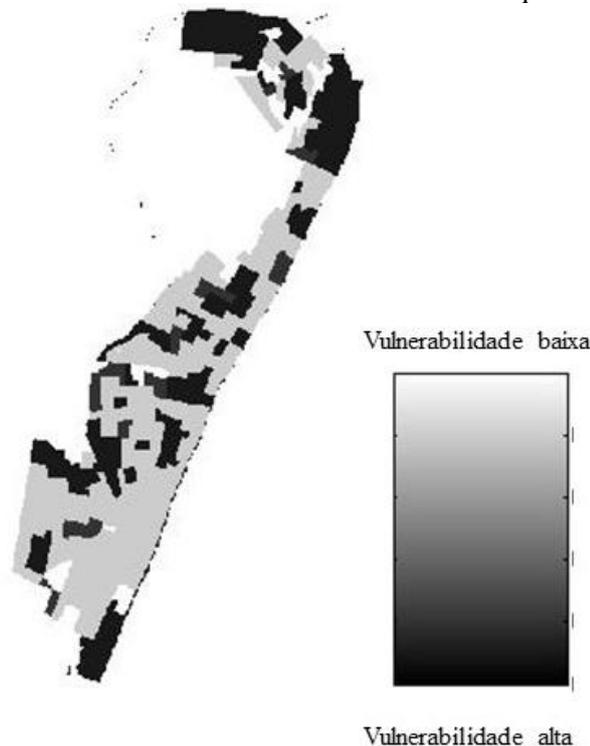


Figura 4. Áreas de vulnerabilidade da região em estudo, de acordo com a abordagem GIS-MCDA e sensoriamento remoto.

Através da Figura 4, pode-se observar que existe uma certa aglomeração de regiões 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.

Com relação as classificações houve pequenas variações nas classificações, ou seja, algumas classes não foram usadas. Entretanto, Camacho-Collados *et al.* (2015) destacam que locais menores para análises espaciais para segurança pública, produzem resultados mais condizentes



com a realidade, pois captam informações que não seriam observados considerando um bairro, por exemplo. Como aplicado o sensoriamento remoto, então é possível analisar estes pequenos espaços. Então, foram usadas imagens de satélite para modificar o desempenho da região em relação a cada critério, visto que existem locais com, características de uso do solo diferentes (uma vez que é contra produtivo avaliar a vulnerabilidade de um parque, por exemplo).

Tendo em vista os resultados, políticas públicas podem ser implantadas nos locais mais vulneráveis a fim de reduzir as fraquezas existentes e, conseqüentemente, impactar na redução da violência. Por exemplo, muitas das áreas mais vulneráveis apresentam problemas de infraestrutura, então políticas públicas podem ser tomadas no sentido de implantar melhores condições de moradia (iluminação pública, água encanada e tratamento de esgoto). A região de aplicação é conhecida pelas discrepantes características sociais e econômicas, havendo um grande contraste entre edifícios luxuosos e favelas. Algumas medidas podem ser tomadas pelo poder público, portanto, para suavizar tais 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, pode ser interessante adotar um planejamento de políticas 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 das alternativas de referência, eliminando a necessidade de limiares de preferência / indiferença e pesos para os critérios. Portanto, com esse método, o decisor pode se sentir mais confortável para 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 (para problemas envolvendo decisão em grupo).

Foi feita uma comparação do resultado do modelo com os homicídios ocorridos na região escolhida entre os anos de 2008 e 2013. A Figura 5 mostra a comparação entre as áreas de vulnerabilidade e os homicídios da área. Os mapas sugerem que os locais classificados como 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 5. Comparação das áreas de vulnerabilidade e os homicídios na região em estudo.

6. Conclusões

O presente estudo visou contribuir com uma área pouco explorada pela integração GIS-MCDA: a segurança pública. Apresentou-se, portanto, um modelo para identificar regiões vulneráveis, através da abordagem DRSA. Além disso, foi somada à abordagem o sensoriamento remoto, a fim de identificar com maior precisão os locais que realmente precisam de intervenções de políticas públicas.

Uma das grandes vantagens na abordagem proposta é a consideração do conjunto de alternativas no formato raster, no qual divide cada alternativa como pixel. Pixels de 0,25x0,25 metros foram adotados, tornando as unidades de análise consideravelmente menores do que aquelas usadas em outros trabalhos (setores censitários, por exemplo). . A outra vantagem é que, através das imagens obtidas por satélite, regiões que não precisam da avaliação espacial são excluídas, tais como rios, florestas, aeroportos e praias.

A classificação da região 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, conseqüentemente, uma redução da violência no longo prazo.

Constatou-se que o método DRSA é adequado para esse contexto, visto que é de fácil aplicação para o decisor, pois não requer um esforço cognitivo significativo por parte dele, como definição de limiares e pesos. Ainda, fez-se uma comparação entre a saída do modelo proposto e o mapa de densidade de homicídios da área, revelando que há uma forte ligação entre a classificação feita e os homicídios. 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



- Agarwal, R. e Garg, P. K. (2016). Remote sensing and GIS based groundwater potential & recharge zones mapping using multi-criteria decision making technique. *Water Resource Management*, 30:243-260.
- Andresen, M. A. (2013). Unemployment, business cycles, crime, and the Canadian provinces. *Journal of Criminal Justice*, 41:220-227.
- 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.
- Camacho-Collados, M., Liberatore, F., & Angulo, J. M. (2015). A multi-criteria Police Districting Problem for the efficient and effective design of patrol sector. *European Journal of Operational Research*, 246:674-684.
- Carver, S. J. (1991). Integrating multi-criteria evaluation with geographical information systems. *International Journal of Geographical Information Systems*, 5:321-339.
- Chakhar, S., & Mousseau, V. (2008). GIS - based multicriteria spatial modeling generic framework. *International Journal of Geographical Information Science*, 22: 1159-1196.
- El Maguiri, A., Kissi, B., Idrissi, L., Souabi, S. (2016). Landfill site selection using GIS, remote sensing and multicriteria decision analysis: case of the city of Mohammedia, Morocco. *Bulletin of Engineering Geology and the Environment*, Published Online.
- Fernández, I. C. e Morales, N. S. (2016). A spatial multicriteria decision analysis for selecting priority sites for plant species restoration: a case study from the Chilean biodiversity hotspot. *The Journal of the Society for Ecological Restoration*, Published Online.
- Figueiredo, C. J. J. e Mota, C. M. M. (2016). A classification model to evaluate the security level in a city based on GIS-MCDA. *Mathematical Problems in Engineering*, 35344824: 1-10.
- Figueiredo, C. J. J., Pereira, D. V. S. e Mota, C. M. M. (2015). Classification of areas using a multiple criteria approach for a public security problem. In *Proceedings of IEEE International Conference Engineering and Engineering Management (IEEM)*, p.524-528, Singapore. IEEE.
- Gurgel, A. M. e Mota, C. M. M. (2013). Multicriteria prioritization model to support public safety planning. *Operational Research*, 33, 251-267.
- Hazarika, N., Barman, D., Das, A. K., Sarma, A. K. e S. B. Borah. (2016). Assessing and mapping flood hazard, vulnerability and risk in the Upper Brahmaputra River valley using stakeholders' knowledge and multicriteria evaluation (MCE). *Journal of Flood Risk Management*, Published Online.
- Instituto Brasileiro de Geografia e Estatística (IBGE). (2015). *Censo demográfico 2010 - Resultados do universo*. <http://censo2010.ibge.gov.br/>. Acessado em 04/02/2015.
- Jankowski, P. (1995). Integrating geographical information systems and multiple criteria decision making methods. *International Journal of Geographical Information Systems*, 9:251-273.
- Jelokhani-Niaraki, M. e Malczewski, J. (2015). A group multicriteria spatial decision support system for parking site selection problem: A case study. *Land Use Policy*, 42:492-508.



Jelokhani-Niaraki, M., & Malczewski, J. (2014). The decision task complexity and information acquisition strategies in GIS-MCDA. *International Journal of Geographical Information Science*, 29:327-344.

Landsat 8. Available: <http://landsat.usgs.gov/landsat8.php>;[accessed 25.11.2016].

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.

Malczewski, J. & Rinner, C. (2015). *Multicriteria Decision Analysis in Geographic Information Science Science*. Springer Science, New York, 2015.

Malczewski, J. (1999). A GIS-based approach to multiple criteria group decision-making. *International Journal of Geographical Information Science*, 10:955-971.

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*, 120:97-99.

Montgomery, B., Dragicevic, S., Dujmovic, J. e Schmidt, M. (2016). A GIS-based Logic Scoring of Preference method for evaluation of land capability and suitability for agriculture. *Computers and Electronics in Agriculture*, 124: 340-353.

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.

Pradhan, A. M. S. e Kim, Y. T. (2016). Evaluation of a combined spatial multi-criteria evaluation model and deterministic model for landslide susceptibility mapping. *Catena*, 140:125-139.

Rahman, Md. R. e Saha, S. K. (2008). Remote sensing, spatial multi criteria evaluation (SMCE) and analytical hierarchy process (AHP) in optimal cropping pattern planning for a flood prone area. *Journal of Spatial Science*, 53:161-177.

Richards, J. A. e Jia, X. *Remote Sensing Digital Image Analysis: An introduction*. Springer, 2006, New York.

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.

Sánchez-Lozano, J. M., García-Cascales, M. S. e Lamata, M. T. (2016). GIS-based onshore wind farm site selection using Fuzzy Multi-Criteria Decision Making methods. Evaluating the case of Southeastern Spain. *Applied Energy*, 171:86-102.

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.