

O PROBLEMA MULTI-OBJETIVO DE ROTEAMENTO E COBERTURA NUM CONTEXTO DE GERENCIAMENTO DE CRISE

Maria José Pinto Lamosa

Instituto de Estudos Avançados (IEAv)
Trevo Cel Av José A. A. do Amarante, nº 1, Putim, CEP 12228-001, São José dos Campos, SP
maju@ieav.cta.br

Mônica Maria De Marchi

Instituto de Estudos Avançados (IEAv)
Trevo Cel Av José A. A. do Amarante, nº 1, Putim, CEP 12228-001, São José dos Campos, SP
monica@ieav.cta.br

Daniel Merli Lamosa

Universidade de Taubaté (UNITAU)
Avenida Marechal Deodoro, nº 605, Jardim S^{ta} Clara, Taubaté, SP
daniel.lamosa@unitau.br

RESUMO

Este trabalho busca apoiar o processo de tomada de decisão em um contexto de gerenciamento de crise para tratar um problema de roteamento específico cujo objetivo é determinar rotas eficientes para cobrir uma região onde existem áreas, denominadas sensíveis, que precisam ser revisitadas o mais breve possível. Uma formulação matemática foi proposta anteriormente para o problema, que foi modelado como um problema multi-objetivo devido ao *trade-off* entre a maximização dos retornos e a minimização dos custos. Neste trabalho, aplicamos uma metodologia multi-objetivo para resolver o problema, baseada na formulação proposta e apresentamos algumas análises e resultados.

PALAVRAS CHAVE. Problema de roteamento e cobertura, Multiobjetivo, Gerenciamento de crise.

Logística & Transporte

ABSTRACT

This work aims to support the decision making process in a crisis management context, considering a specific routing problem where the objective is to determine efficient routes to cover areas in a region where some of them are considered critical and should be revisited as soon as possible. In a previous work, a multi-objective formulation was proposed considering the trade-off between the minimum cost route and the maximum returns to critical areas. In this work, we applied a multi-objective methodology based on this formulation to solve the problem. Some analysis and results will be presented.

KEYWORDS. Covering-routing problem. Multi-objective. Crisis Management.

Logistic & Transport

1. Introdução

O processo de tomada de decisão dentro de um contexto de gerenciamento de crises naturais (como enchentes e calamidades) é extremamente complexo e desafiador, pois envolve incertezas e uma grande variedade de informações e de entidades responsáveis pela tomada de decisão, que deverá ser uma decisão tomada em conjunto de forma eficaz e eficiente.

Dentro deste contexto, este trabalho pretende apoiar a tomada de decisão aplicando conceitos da Pesquisa Operacional (Goldbarg e Luna, 2000; Daskin, 1995) para tratar um problema de roteamento específico onde o objetivo é determinar uma rota eficiente para cobrir áreas em uma determinada região onde algumas destas áreas, denominadas sensíveis, precisam ser revisitadas o mais breve possível. Para garantir que as áreas permaneçam descobertas o mínimo de tempo possível seria interessante buscar a maximização dos retornos a estas áreas. Por outro lado, se as áreas sensíveis forem visitadas muitas vezes, a rota pode resultar em um custo muito alto. Assim, existe um *trade-off* entre a maximização dos retornos e a minimização dos custos.

Em trabalhos anteriores (Lamosa *et al.*, 2011a, 2011b), este problema foi denominado CRPMRCA (do inglês, *Covering-Routing Problem with Maximum Returns to Critical Areas*) e uma formulação matemática foi proposta para sua resolução. Neste trabalho, apresentamos uma metodologia multi-objetivo (Deb, 2001) para tratar o problema, baseada nesta formulação matemática, onde os primeiros resultados são apresentados.

Como aplicação, os resultados deste trabalho podem ser utilizados para apoio à decisão em duas situações da crise: pré e pós-evento. A decisão pré-evento consistiria em medidas preventivas, onde o roteamento gerado poderia ser aplicado para monitoramento de áreas de risco (sensíveis) facilitando o planejamento de evacuações ou de possíveis restaurações destas áreas. Na decisão pós-evento, o mesmo monitoramento poderia ser realizado, mas agora o objetivo seria permitir uma visão do cenário atual (mostrando o impacto de danos causados pelo desastre) de forma a facilitar a tomada de decisão para, por exemplo, gerar rotas alternativas para as entidades que vão realizar o apoio. As áreas sensíveis, neste caso, poderiam ser áreas com perigo de deslizamento e que poderiam, em algum momento, inviabilizar uma rota gerada para uma entidade de apoio. O monitoramento também permitiria ainda a identificação de locais seguros para transporte e abrigo de vítimas.

2. Formulação para o CRPMRCA

De nosso conhecimento, o CRPMRCA não foi tratado na literatura mas pode ser visto como uma variação do TSP (do inglês, *Traveling Salesman Problem*) pois, para um melhor entendimento do problema estamos considerando, até o momento, uma versão simplificada, onde temos uma única entidade para realização da rota com capacidade ilimitada (Goldbarg e Luna, 2000). Assim, a formulação proposta será baseada na formulação do TSP (Goldbarg e Luna, 2000; Daskin, 1995; Gutin e Punnen, 2007), com a alteração de, não somente permitir retornos às áreas sensíveis, mas também maximizá-los.

Considerando:

- N → conjunto de áreas a serem cobertas (monitoradas);
- M → conjunto de áreas sensíveis ($M \subset N$);
- c_{ij} → custo para atravessar o arco (i, j) , ou seja, distância entre as áreas i e j ;
- x_{ij} → variável de decisão que será 1, se o arco (i, j) pertencer à rota e 0, caso contrário.
- y_i → variável de decisão que representará os retornos às áreas sensíveis i , $i \in M$. Como estamos considerando que uma área é visitada se a rota passa por esta área ($x_{ij} = 1$ ou $x_{ji} = 1$), podemos considerar: $y_i = \sum_{i \in N} x_{ij}$, $i \in M$.

o problema CRPMRCA pode ser modelado como:

$$\begin{aligned} \text{CRPMRCA} = \min & \sum_{i \in N} \sum_{j \in N} c_{ij} x_{ij} \\ & \max \sum_{i \in M} y_i \end{aligned} \quad (1)$$

$$\text{sujeito a: } \sum_{j \in N} x_{ij} - \sum_{j \in N} x_{ji} = 0 \quad i \in N \quad (2)$$

$$\sum_{j \in N} x_{ij} \geq I \quad i \in M \quad (3)$$

$$\sum_{i \in N} x_{ij} \geq I \quad j \in M \quad (4)$$

$$\sum_{j \in N} x_{ij} = I \quad i \in (N-M) \quad (5)$$

$$\sum_{i \in N} x_{ij} = I \quad j \in (N-M) \quad (6)$$

$$x_{ij} \in \{0, I\} \quad (7)$$

O objetivo (1) busca atender o *trade-off* entre a minimização dos custos e a maximização dos retornos. As restrições (2) são restrições de conservação de fluxo. Os retornos às áreas sensíveis são permitidos pelas restrições (3) e (4) e são evitados para as áreas não sensíveis pelas restrições (5) e (6). As restrições (7) definem as variáveis como binárias.

A formulação (1)-(7) não evita a formação de sub-ciclos. Para isto, as restrições (8) precisam ser incluídas no modelo:

$$\sum_{i \in S} \sum_{j \notin S} x_{ij} \geq I \quad (8)$$

onde S é o conjunto de nós pertencentes a cada possível sub-ciclo.

3. Resolução do CRPMRCA

Deb (2001) apresenta vários métodos para tratar problemas multi-objetivos e buscar as soluções de compromisso que compõem a curva de *trade-off*. O autor apresenta os chamados métodos clássicos e os métodos evolutivos. Dentre os métodos clássicos citados pelo autor, vamos utilizar o “método ϵ -restrito”, que consiste em reformular o problema considerando somente um dos objetivos e incluindo os demais como restrições do problema limitadas a um valor específico, o qual é atualizado iterativamente de forma a gerar os valores da curva de *trade-off*.

Para o nosso problema, existem duas abordagens: a) maximizarmos os retornos, limitados a restrições de custo (*Max_Retorno*) b) minimizarmos os custos, com restrições em relação a quantidade de retornos às áreas sensíveis (*Min_Custo*). Para verificar qual abordagem seria mais indicada para o nosso problema, realizamos testes considerando ambas as abordagens, as quais serão mais detalhadas a seguir.

3.1 Abordagem *Max_Retorno*

Nesta abordagem, consideramos a maximização dos retornos, onde estes retornos estarão sujeitos a uma limitação de custo ϵ , ou seja:

$$\sum_{i \in N} \sum_{j \in N} c_{ij} x_{ij} \leq \epsilon \quad (9)$$

Assim, o problema mono-objetivo a ser resolvido, a cada iteração, será:

$$\max \sum_{i \in M} y_i \quad (10)$$

sujeito a: restrições (2)-(9)

Os valores de ε serão atualizados a cada iteração da seguinte forma:

$$\varepsilon = C_{min} + pC_{min}, \quad 0 \leq p \leq p_{max} \quad (11)$$

ou seja, o valor de ε será uma porcentagem de um custo mínimo (C_{min}), o qual é obtido resolvendo o seguinte problema:

$$C_{min} = \min \sum_{i \in N} \sum_{j \in N} c_{ij} x_{ij} \quad (12)$$

sujeito a: restrições (2)-(8)

ou seja, é o problema original relaxando o segundo objetivo (agora, os retornos são permitidos e não maximizados).

3.2 Abordagem *Min_Custo*

Nesta abordagem, consideramos a minimização de custo e restringimos os retornos a um limite ε , ou seja:

$$\sum_{i \in M} y_i \geq \varepsilon \quad (13)$$

Assim, o problema mono-objetivo a ser resolvido, a cada iteração, será:

$$\min \sum_{i \in N} \sum_{j \in N} c_{ij} x_{ij} \quad (14)$$

sujeito a: restrições (2)-(8), (13)

O

os valores de ε representarão o retorno a cada área sensível. Este valor será atualizado ($\varepsilon = \varepsilon + l$) a cada iteração até que C_{max} seja atingido. Consideramos:

$$C_{max} = kC_{min} \quad (15)$$

onde C_{min} é obtido também com a resolução do problema (12).

Para resolver os problemas (10) (12) e (14), para cada valor de ε , utilizamos o pacote de otimização GLPK (GLPK, 2011) sem as restrições (8), pois correspondem a um número grande de restrições. Estas restrições somente serão incluídas nos modelos, caso um ou mais ciclos sejam identificados. Neste caso, incluimos as restrições (8) correspondentes que evitam este(s) ciclo(s) gerado(s) e utilizamos novamente o pacote para resolver o novo problema (com as restrições (8) correspondentes incluídas). Caso novos ciclos sejam identificados, as restrições (8) correspondentes são incluídas no modelo e o problema novamente resolvido. Este procedimento é repetido até que todos os sub-ciclos tenham sido eliminados.

4. Resultados

Os testes computacionais foram realizados utilizando algumas instâncias obtidas da TSPLIB (Reinelt, 1991) para o TSP, onde são fornecidos N pontos e o custo dos arcos entre eles. Para utilizar estas instâncias consideramos os pontos como sendo as áreas a serem cobertas e criamos um gerador aleatório para selecionar um conjunto $M \subset N$ de áreas e considerá-las sensíveis. Para cada instância, consideramos diferentes valores de M para mostrar o comportamento do método para uma quantidade pequena, média e grande de áreas sensíveis em relação ao total de áreas, ou seja, consideramos: $M = 0,25N$; $M = 0,50N$ e $M = 0,75N$, respectivamente.

Para testar a metodologia, consideramos $p_{max} = 1$ em (11) e $k = 2$ em (15), ou seja, o valor de ε será, no máximo, o dobro do custo mínimo obtido (C_{min}), em ambas as abordagens. No caso, variamos o valor de p de $0,1$ em $0,1$.

Os testes foram realizados num microcomputador Intel Core 2Duo, 3.0GHz e 4GB de RAM e os resultados obtidos estão apresentados nas Tabelas 1 a 3. As Tabelas 1 e 2 apresentam os resultados para as abordagens *Max_Returno* e *Min_Custo*, respectivamente.

Em ambas as tabelas são apresentados o custo (coluna C) e o retorno (coluna R) para todos os casos de testes. E a Tabela 1 ainda apresenta os valores de p correspondentes a cada solução. As soluções dominadas estão apresentadas em negrito na Tabela 1. Nestes casos, a quantidade de retornos é igual ao de outra solução gerada mas com custo maior (caso burma14, $M=3$, $p=0,4$ e $p=0,8$). Estas soluções não são consideradas na curva de *trade-off*.

Tabela 1: Resultados obtidos com a abordagem *Max_Returno*.

	N	M	p	C	R		N	M	p	C	R		N	M	p	C	R
burma14	14	3	0	3454	0	gr21	21	5	0	2707	0	bays29	29	7	0	2020	0
			0,1	3702	2				0,1	2967	3				0,1	2222	4
			0,2	4131	3				0,2	3246	5				0,2	2423	8
			0,3	4486	5				0,3	3515	7				0,3	2623	10
			0,4	4787	5				0,4	3786	9				0,4	2828	13
			0,5	5136	6				0,5	4060	10				0,5	3029	15
			0,6	5525	7				0,6	4318	11				0,6	3228	17
			0,7	5818	8				0,7	4580	13				0,7	3433	19
			0,8	6212	8				0,8	4872	14				0,8	3636	20
			0,9	6488	9				0,9	5118	15				0,9	3835	22
1	6820	10	1	5407	16	1	4038	23									
burma14	14	7	0	3454	0	gr21	21	10	0	2707	0	bays29	29	14	0	2020	0
			0,1	3788	3				0,1	2959	5				0,1	2221	6
			0,2	4116	5				0,2	3245	7				0,2	2424	9
			0,3	4484	7				0,3	3517	9				0,3	2626	12
			0,4	4753	8				0,4	3786	11				0,4	2828	15
			0,5	5172	10				0,5	4036	13				0,5	3027	18
			0,6	5514	11				0,6	4327	14				0,6	3230	20
			0,7	5864	12				0,7	4599	16				0,7	3432	23
			0,8	6212	13				0,8	4868	17				0,8	3635	25
			0,9	6557	14				0,9	5137	19				0,9	3836	27
1	6908	15	1	5413	20	1	4040	29									
burma14	14	10	0	3454	0	gr21	21	15	0	2707	0	bays29	29	21	0	2020	0
			0,1	3795	4				0,1	2976	5				0,1	2222	6
			0,2	4126	6				0,2	3247	9				0,2	2419	11
			0,3	4485	9				0,3	3515	12				0,3	2625	15
			0,4	4813	11				0,4	3789	14				0,4	2825	19
			0,5	5162	13				0,5	4052	17				0,5	3030	22
			0,6	5517	14				0,6	4328	19				0,6	3227	26
			0,7	5855	16				0,7	4594	22				0,7	3434	29
			0,8	6203	17				0,8	4869	23				0,8	3636	31
			0,9	6542	18				0,9	5132	26				0,9	3838	34
1	6908	20	1	5412	28	1	4038	37									

Para verificar qual abordagem seria melhor para o nosso problema, montamos a Tabela 2 somente com os resultados, obtidos com a abordagem *Min_Custo*, que apresentaram o mesmo número de retornos apresentados na Tabela 1. Os resultados mostram que a abordagem *Min_Custo* é a mais indicada pois, na maioria dos casos, apresentou resultados melhores do que a abordagem *Max_Returno*. Destacamos, em negrito na Tabela 2, os casos onde os resultados foram iguais.

A abordagem *Min_Custo* também fornece o custo para valores intermediários de retornos. Por exemplo, no caso gr21 e $M = 15$ da Tabela 1, é apresentado o valor de custo para $R=5$ e $R=9$ (referentes a $p=0,1$ e $p=0,2$). Mas, esta abordagem não fornece os custos para $R=6, 7$ e 8 , ao contrário da abordagem *Min_Custo*, que fornece estes custos para todos os valores sucessivos de R . Estes valores podem ser interessantes para um decisor, caso a limitação de custo permita um total de retorno entre 5 e 9.

Tabela 2: Resultados obtidos com a abordagem *Min_Custo*.

	<i>N</i>	<i>M</i>	<i>C</i>	<i>R</i>		<i>N</i>	<i>M</i>	<i>C</i>	<i>R</i>		<i>N</i>	<i>M</i>	<i>C</i>	<i>R</i>
burma14	14	3	3454	0	gr21	21	5	2707	0	bays29	29	7	2020	0
			3550	2				2967	3				2177	4
			3841	3				3196	5				2421	8
			4486	5				3467	7				2564	10
			4870	6				3784	9				2814	13
			5259	7				3984	10				2993	15
			5762	8				4179	11				3188	17
			6269	9				4579	13				3417	19
			6820	10				4784	14				3548	20
							5209	16					3952	23
burma14	14	7	3454	0	gr21	21	10	2707	0	bays29	29	14	2020	0
			3775	3				2945	5				2220	6
			4073	5				3137	7				2396	9
			4447	7				3384	9				2591	12
			4658	8				3667	11				2802	15
			5145	10				4010	13				3021	18
			5405	11				4178	14				3178	20
			5702	12				4530	16				3406	23
			5977	13				4723	17				3576	25
			6274	14				5073	19				3762	27
							5288	20					3952	29
burma14	14	10	3454	0	gr21	21	15	2707	0	bays29	29	21	2020	0
			3754	4				2912	5				2183	6
			4052	6				3227	9				2399	11
			4472	9				3479	12				2595	15
			4770	11				3671	14				2804	19
			5140	13				4007	17				2984	22
			5284	14				4227	19				3224	26
			5806	16				4594	22				3410	29
			6116	17				4741	23				3550	31
			6336	18				5132	26				3798	34
							5407	28					4008	37

A abordagem *Min_Custo* apresentou melhores resultados num menor tempo computacional, como mostra a Tabela 3, que apresenta o tempo computacional total utilizado para cada caso de teste, para ambas as abordagens. A tabela também mostra um aumento já esperado no tempo, a medida que N cresce.

Tabela 3: Resultado em relação ao tempo computacional (em segundos).

	<i>N</i>	<i>M</i>	<i>Max_Returno</i>	<i>Min_Custo</i>
burma14	14	3	4,38	0,39
	14	7	8,36	0,78
	14	10	5,99	1,25
gr21	21	5	15,63	1,47
	21	10	35,55	2,03
	21	15	51,28	4,51
bays29	29	7	85,71	12,92
	29	14	55,65	10,28
	29	21	112,92	20,45

A Figura 1 apresenta o gráfico entre o custo e o retorno (curva de *trade-off*) para um dos resultados apresentados (caso burma14, *M*=7), tendo em vista que os demais resultados apresentam um comportamento similar. Este gráfico foi construído para mostrar que esta forma de apresentar o resultado pode ser interessante para apoiar decisores em um processo de tomada de decisão, pois é possível visualizar o *trade-off* entre os dois objetivos. Assim, se o decisor tiver um intervalo de limitação de custo, por exemplo, poderá optar pelo melhor retorno que consegue atingir.

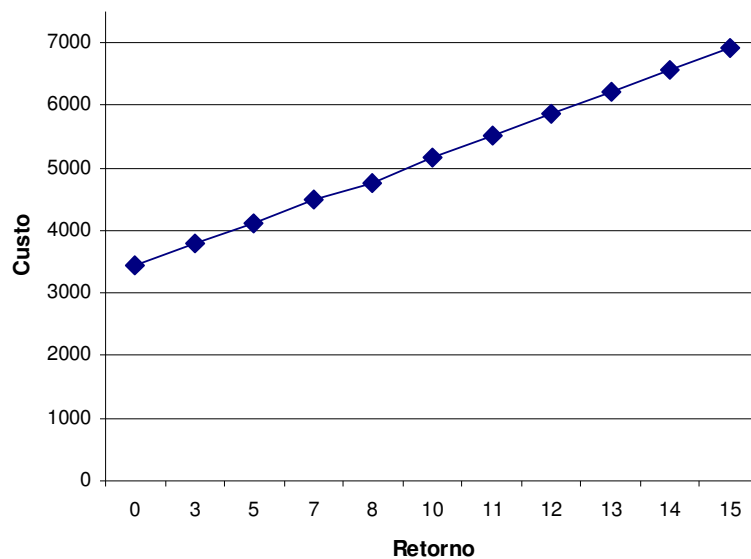


Figura 1: Gráfico Custo x Retorno.

Definida a melhor abordagem para o nosso problema, apresentamos a seguir uma análise em relação à formulação (1)-(7), que consiste em avaliar a possibilidade de alterar a formulação proposta de forma a permitir (não maximizar) os retornos às áreas não-sensíveis. Para isto, bastaria relaxar as restrições (5) e (6) da seguinte forma:

$$\sum_{j \in N} x_{ij} \geq l \quad i \in (N-M) \quad (16)$$

$$\sum_{i \in N} x_{ij} \geq l \quad j \in (N-M) \quad (17)$$

Para verificar esta possibilidade, os testes foram refeitos, considerando a abordagem *Min_Custo*, e os casos onde um resultado melhor foi obtido estão apresentados na Tabela 4. Os resultados mostraram que, quando esta alteração for viável para a aplicação (por exemplo, num contexto de gerenciamento de crise, quando a rota gerada for utilizada

para monitoramento), pode ser vantajoso permitir estes retornos pois foi possível obter o mesmo número de retornos com um custo menor e, em alguns casos (destacados em negrito) um número máximo maior de retornos foi possível.

Tabela 4: Resultado permitindo retornos para as áreas não-sensíveis.

	<i>N</i>	<i>M</i>	<i>C</i>	<i>R</i>
burma14	14	10	6114	17
gr21	21	5	3966	10
			4166	11
			4561	13
			4761	14
			4966	15
			5171	16
			5391	17
gr21	21	10	3129	7
			3321	9
			3578	11
			3881	13
			4042	14
			4392	16
			4575	17
			4927	19
			5085	20
5279	21			
gr21	21	15	3213	9
			3963	17
			4201	19
			4568	22
			4666	23
			5057	26
			5337	28
bays29	29	7	3406	19
			3533	20
			3787	22
			3917	23
bays29	29	14	3757	27
			3943	29
			4038	30

5. Trabalhos futuros

Analisando os resultados observamos que, apesar do aumento do número total de retornos à medida que relaxamos o custo, algumas áreas sensíveis continuavam não sendo revisitadas, tanto na abordagem *Max_Retorno* quanto na abordagem *Min_Custo*, como pode ser visto nas Figuras 2 e 3, respectivamente. Estas figuras mostram o número de retornos a cada área considerando as soluções apresentadas para o mesmo caso da Figura 1 (caso burma14, $M=7$). Observe que, tanto na Figura 2 quanto na Figura 3, as áreas sensíveis 5 e 10 não foram revisitadas.

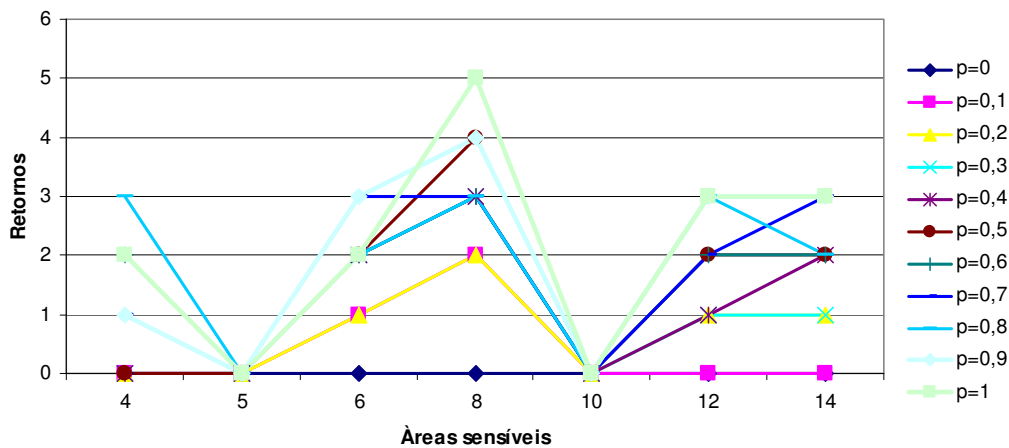


Figura 2: Gráfico mostrando o retorno a cada área sensível (abordagem *Max_Returno*).




Figura 3: Gráfico mostrando o retorno a cada área sensível (abordagem *Min_Custo*).

Isto ocorreu provavelmente devido ao alto custo para visitar estas áreas. Para tentar contornar este problema e permitir que os retornos sejam mais distribuídos entre as áreas sensíveis, estamos avaliando algumas possibilidades. Uma primeira tentativa seria modificar os problemas *Max_Returno* e *Min_Custo* de forma a maximizar o retorno a cada área sensível e não ao somatório dos retornos. Uma outra tentativa para permitir esta melhor distribuição seria a inclusão de prioridades a cada área sensível, ou seja, que os pesos associados a cada área sensível sejam definidos de forma a não refletir somente o custo (distância) para chegar a esta área.

Além disso, o próximo passo será aplicar outras metodologias multi-objetivo para tratar o problema CRPMRCA de forma a permitir uma comparação dos resultados obtidos. Uma primeira abordagem que está em desenvolvimento é o algoritmo genético, um dos métodos evolutivos citados em Deb (2001). Este método já foi bastante utilizado para problemas de roteamento multi-objetivo. Assim, nosso trabalho será realizar as adaptações necessárias para tratar o problema proposto, ou seja, permitir e maximizar retornos às áreas sensíveis.

Por ser uma primeira tentativa de tratar o problema, também fizemos algumas simplificações no modelo que podem dificultar a aplicação direta dos resultados a problemas reais. Para possibilitar esta aplicação, seria importante incluir limitações e características ao problema como, por exemplo, o tempo associado ou a autonomia/capacidade da entidade que realizará o roteamento

6. Considerações finais

Este trabalho apresentou uma metodologia multi-objetivo para tratar o problema de roteamento e cobertura proposto, cujo objetivo é maximizar o retorno às áreas sensíveis buscando não resultar num aumento indesejável do custo. Foram feitos alguns testes computacionais e os resultados foram apresentados. Algumas melhorias também foram propostas para resolver o problema, sendo que algumas delas já estão em desenvolvimento.

Além da aplicação em sistemas de gerenciamento de crise citada anteriormente, acreditamos que os resultados deste trabalho podem ser aplicados em outros sistemas onde ações críticas e monitoramento são necessários como em sistemas de busca e salvamento e de vigilância do espaço aéreo.

Referências

- Daskin, M.**, *Network and Discrete Location: Models, Algorithms and Applications*, Wiley Interscience, New York, EUA, 1995.
- Deb, K.**, *Multi-objective Optimization using Evolutionary Algorithms*, John Wiley & Sons, 2001.
- GLPK** (GNU Linear Programming Kit), 2011, Disponível em: <http://www.gnu.org/software/glpk/>. Acesso em 01/05/2011.
- Goldbarg, M. C., Luna, H. P. L.**, *Otimização Combinatória e Programação Linear: Modelos e Algoritmos*, Editora Campus, R. J., 2000.
- Gutin, G. e Punnen, A. P.**, *The Traveling Salesman Problem and its Variations*, Springer, New York, EUA, 2007.
- Lamosa, M. J. P., Lamosa, D. M. e De Marchi, M. M.** (2011a), An interactive approach to solve a multi-objective covering-routing problem considering critical areas, *1st CogSIMA (Conference on Cognitive Methods in Situation Awareness and Decision Support)*, Miami Beach, Flórida, EUA, 115-118.
- Lamosa, M. J. P., Lamosa, D. M. e De Marchi, M. M.** (2011b), Heurística modificada para um problema de roteamento e cobertura com maximização de retornos às áreas sensíveis – resultados computacionais, *XLIII Simpósio Brasileiro de Pesquisa Operacional (SBPO)*, Ubatuba, SP, 1535-1546.
- Reinelt, G.**, (1991), TSPLIB: A traveling salesman problem library, *ORSA Journal on Computing*, 3, 376-384.