



SPOLM 2008

ISSN 2175-6295

Rio de Janeiro- Brasil, 05 e 06 de agosto de 2008.

## UMA METODOLOGIA PARA OTIMIZAÇÃO DA DISTRIBUIÇÃO DE DETECTORES DE AGENTES QBRN

**Paulo Alexandre de Moraes Cabral**

Centro Tecnológico do Exército

Divisão de Defesa Química, Biológica e Nuclear

Seção de Defesa Química

Av. das Américas 28705 – Guaratiba – Rio de Janeiro, RJ

[paulo@ctex.eb.br](mailto:paulo@ctex.eb.br)

**Vinícius Correa Damaso**

Centro Tecnológico do Exército

Divisão de Defesa Química, Biológica e Nuclear

Seção de Defesa Nuclear

Av. das Américas 28705 – Guaratiba – Rio de Janeiro, RJ

[damaso@ctex.eb.br](mailto:damaso@ctex.eb.br)

### RESUMO

Um dos cenários de terrorismo mais alarmantes é o uso de armas de destruição em massa, como armas de natureza Química, Biológica, Radiológica ou Nuclear (QBRN), contra a população civil. A habilidade para detectar agentes químicos ou produtos químicos industriais tóxicos é então vital para proteger aqueles que estão na linha de frente e o público em geral. Felizmente, algumas tecnologias de detecção têm-se mostrado adequadas e uma variedade de detectores de agentes QBRN pode ser encontrada. O propósito deste trabalho é apresentar uma metodologia para a seleção da distribuição ótima de um número predeterminado de detectores de agentes QBRN em uma área de risco, onde liberações acidentais ou intencionais podem ocorrer com uma maior frequência. Um estudo de caso foi desenvolvido para uma planta laboratorial hipotética, usando um algoritmo genético simples (AG) como ferramenta de otimização. Os resultados demonstram a aplicabilidade e a eficiência da metodologia proposta.

**Palavras-Chaves:** Otimização; Agentes QBRN; Algoritmo Genético; CFD.

### Abstract

One of the most alarming terrorism scenarios is the use of mass destruction weapons, as Chemical, Biological, Radiological or Nuclear weapons (CBRN), against civil population. The ability to detect Chemical Agents (CA) or Toxic Industrial Chemicals (TICs) is therefore vital to protect those in the front line and the public at large. Fortunately, some detection technologies have been shown adequate and a variety of CBRN detectors can be found. The purpose of this work is to provide a methodology of selecting the optimal distribution of a

pre-determined number of CBRN agent detectors in a risk area, where accidental or intentional releases may occur with a greater frequency. A case study was developed to a hypothetical laboratorial plant, using a simple genetic algorithm (GA) as optimization tool. The results demonstrate the applicability and the efficiency of the proposed methodology.

**Keywords:** Optimization; CBRN Agents; Genetic Algorithm; CFD.

## 1. INTRODUÇÃO

Um dos cenários mais alarmantes, em relação a ataques terroristas, trata do uso de armas de destruição em massa, como as armas Químicas, Biológicas, Radiológicas e Nucleares (QBRN). Para as forças militares, a ameaça de armas químicas tem existido por décadas e pode afetar radicalmente as operações, particularmente operações terrestres e marítimas. Tal ameaça tem se estendido também à população civil em geral [1]. A capacidade e a habilidade técnica em detectar rapidamente um ataque com agentes químicos ou tóxicos industriais é de suma importância na ação de resposta, de modo a proteger os indivíduos da linha de frente e o público em geral [2]. O uso de TICs (“Toxic Industrial Chemicals” – agentes químicos tóxicos industriais) é um cenário com probabilidade de ocorrência crescente, já que a descarga generalizada de rejeitos industriais é uma prática comum, praticamente em todo o mundo. Adicionalmente, o “National Institute of Justice” dos Estados Unidos fornece uma lista de aproximadamente 100 TICs, classificados em três níveis de ameaça, de acordo com o volume de produção, facilidade de transporte, toxicidade e volatilidade [3].

Felizmente, têm sido desenvolvidas tecnologias adequadas de detecção e uma variedade de detectores pode ser encontrada no mercado atualmente. Os Planos de Resposta a Emergências são baseados na rápida detecção (e/ou identificação) de substâncias perigosas e, uma capacidade efetiva e moderna de detecção deve oferecer sistemas totalmente integrados, com equipamentos de alta sensibilidade, confiáveis, precisos e de fácil operação [4].

Na literatura, são encontrados poucos trabalhos que correlacionam, de alguma maneira, técnicas de resolução de problemas ligados ao apoio à tomada de decisão, relativos à avaliação de cenários e à modelagem de conseqüências para equipes responsáveis pela ação de primeira resposta a emergências QBRN, conforme mencionado em [5,6].

O Sistema de Defesa Química, Biológica e Nuclear, no âmbito do Exército Brasileiro (SDQBNE), prevê o emprego da Companhia de Defesa Química, Biológica e Nuclear (Cia DQBN), diretamente subordinada ao Comando de Operações Terrestres (COTER), como braço operacional e o Centro Tecnológico do Exército (CTEx), através de sua Divisão DQBN, como órgão de Assessoramento Científico. A necessidade do emprego de técnicas mais sofisticadas de predição (e visualização) de plumas e de posicionamento ótimo de sensores de monitoramento tem se mostrado uma realidade atual, à medida que a crescente complexidade das missões tem exigido respostas mais rápidas e precisas.

O propósito deste trabalho é oferecer um mecanismo de suporte à decisão, no que tange a equipes de resposta a emergências QBRN, lançando alguma luz sobre os procedimentos de seleção do número ótimo e melhor posição de sítios de detecção em áreas de risco, onde liberações acidentais ou intencionais podem ocorrer com relativa frequência. Um estudo de caso foi desenvolvido para uma hipotética planta laboratorial, onde há risco de liberação de agente químico. Um Algoritmo Genético (AG) simples foi utilizado como ferramenta de otimização.

## 2. MODELO DE DISPERSÃO

As predições dos movimentos das plumas resultantes das liberações e dos perfis de concentração podem ser obtidas pelo clássico Modelo de Dispersão de Pasquill-Gifford [7,8],

para a situação de fontes contínuas e estacionárias, vento na direção axial  $x$ , a uma dada altura  $H_t$  (em m) a partir do solo:

$$C(x, y, z) = \frac{Q_m}{2\pi\sigma_y\sigma_z u} \exp\left[-\frac{1}{2}\left(\frac{y}{\sigma_y}\right)^2\right] \times \left\{ \exp\left[-\frac{1}{2}\left(\frac{z-H_t}{\sigma_z}\right)^2\right] + \exp\left[-\frac{1}{2}\left(\frac{z+H_t}{\sigma_z}\right)^2\right] \right\} \quad \text{Equação 1}$$

Neste modelo,  $C(x,y,z)$  é a concentração (em  $g/m^3$ ) da pluma no ar,  $Q_m$  é a taxa de liberação (em  $g/s$ ),  $u$  é a velocidade axial do vento (em  $m/s$ ),  $\sigma_y$  e  $\sigma_z$  são os coeficientes de dispersão nas direções ortogonais (em m). Os eixos cartesianos são colocados com origem na posição de cada fonte. Daí,  $x$  é a direção axial do vento,  $y$  é a direção perpendicular horizontal do vento e  $z$  é a direção vertical. Os coeficientes de dispersão são calculados em função da classe de estabilidade de Pasquill-Gifford utilizada e são obtidos por meio de equações da forma:

$$\sigma_y(x) = ax(1+bx)^{-1/2} \quad \text{Equação 2}$$

$$\sigma_z(x) = cx(1+dx)^f \quad \text{Equação 3}$$

onde os valores de  $a$ ,  $b$ ,  $c$ ,  $d$  além de  $f$  são dependentes da classe de estabilidade.

Embora os cálculos de otimização apresentados neste artigo tenham sido obtidos através do uso deste modelo clássico de Pasquill-Gifford, o pacote comercial de CFD (“Computational Fluid Dynamics” – Fluidodinâmica Computacional) PHOENICS® (versão 2007) foi utilizado para comparar os resultados de dispersão de plumas. Neste pacote, o conjunto de equações que governam o processo de dispersão, incluindo as chamadas “relações constitutivas”, é resolvido pela técnica de “volumes finitos”, muito comum na área de CFD [9].

### 3. MODELAGEM GENÉTICA

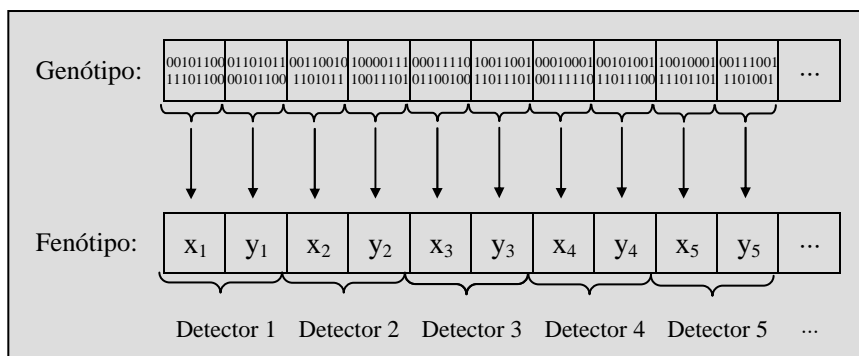
Algoritmos genéticos (AG) são paradigmas de busca de soluções inspirados na metáfora biológica da teoria da evolução das espécies [10]. Um AG manipula uma população de estruturas simbólicas que representam candidatos à solução do problema [11]. Para cada indivíduo, é atribuído um certo grau de aptidão (representado em uma função objetivo) que reflete o quão boa é a solução para o problema. Em função deste grau de aptidão, a população é submetida ao processo evolutivo por meio de operadores genéticos (seleção, combinação, mutação entre outros), levando em conta que os indivíduos mais capazes terão maior probabilidade de reprodução e, assim, maior probabilidade de transferência de suas características para as próximas gerações.

Um AG é uma ferramenta robusta para solução de vários problemas de otimização podendo manipular qualquer tipo de função objetivo não linear e restrições sem qualquer transformação. Por esta característica AGs têm sido aplicados amplamente em diversos problemas de otimização, usualmente de natureza combinatória [12,13,14].

Neste trabalho, um AG é empregado para indicar as coordenadas  $(x_i, y_i)$  de um número pré-estabelecido de detectores, dentro de uma área definida, com o objetivo de otimizar a detecção de agentes químicos tóxicos. Neste processo de otimização, deve-se levar em conta as decisões tomadas previamente e as condições impostas referentes à forma de distribuição dos detectores.

Cada grupo de parâmetros (coordenadas) é metaforicamente chamado de fenótipo, e representa um candidato à solução. Os candidatos à solução são codificados em uma estrutura denominada genótipo. Uma das codificações possíveis, a qual foi utilizada neste trabalho, é usar uma superestrutura, onde o AG reserva 16 bits por parâmetro.

A Figura 1 apresenta uma representação esquemática da estrutura genótipo/fenótipo usada neste trabalho.



**Figura 1. Representação esquemática da estrutura genótipo/fenótipo.**

#### 4. ESTUDO DE UM CASO HIPOTÉTICO

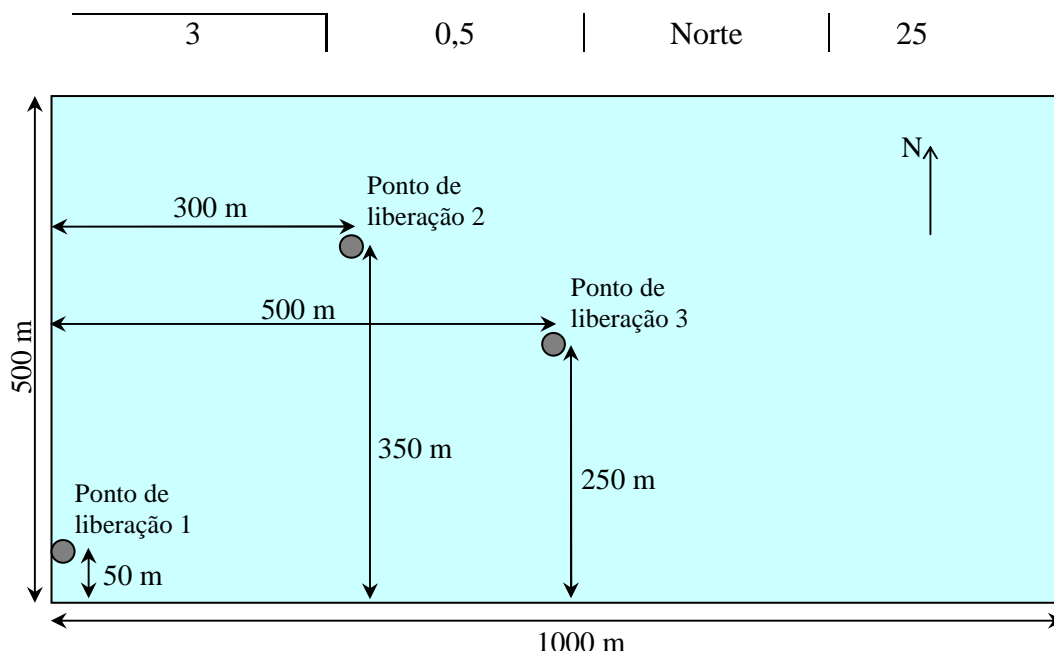
O presente estudo de caso trata da otimização da distribuição de um número determinado de detectores para monitorar a liberação de agentes químicos no ambiente. Um total de oito detectores será distribuído na área de uma planta laboratorial dedicada a pesquisas de antídotos contra agentes químicos. Devido às suas atividades de pesquisa, os laboratórios possuem inventários de agentes químicos de guerra que estão sujeitos a liberação acidental.

A planta laboratorial tem uma área controlada de cerca de  $0,5\text{km}^2$  (1km de extensão e 500m de largura), em zona rural, com três instalações que manipulam compostos químicos tóxicos, localizados conforme mostra a Figura 2. A partir desses pontos é possível ocorrer uma liberação de agente químico.

A região é sujeita a condições climáticas distintas com seus respectivos regimes de vento ao longo do ano, que podem ser simplificados como mostrado na Tabela 1, considerando valores médios representativos.

**Tabela 1. Percentual de regimes de vento ao longo do ano.**

Regime de vento	Velocidade (m/s)	Direção (jusante)	% (anual)
1	2,0	Leste	35
2	4,0	Leste	40



**Figura 2. Vista esquemática da área controlada.**

A Tabela 2 mostra as probabilidades de falhas que podem levar a um cenário de dispersão de agentes químicos para cada um dos possíveis pontos de liberação assinalados na Figura 2.

**Tabela 2. Probabilidades de falhas que levam à dispersão.**

Ponto de liberação	Probabilidade de Falha
1	$1,0 \cdot 10^{-4}$
2	$1,5 \cdot 10^{-4}$
3	$2,2 \cdot 10^{-4}$

Os três pontos de liberação, sujeitos aos três regimes de ventos descritos na Tabela 1, produzem nove possíveis cenários de dispersão de agentes químicos no ambiente, como mostrado na Tabela 3.

**Tabela 3. Cenários de dispersão postulados.**

Ponto de liberação	Regime de vento		
	1	2	3
1	Cenário 1	Cenário 4	Cenário 7
2	Cenário 2	Cenário 5	Cenário 8
3	Cenário 3	Cenário 6	Cenário 9

Todos os cenários envolvem uma fonte contínua produzindo uma pluma que segue a direção de vento. Em todos os casos, a classe de estabilidade atmosférica considerada foi a classe B, em uma zona rural. Dessa forma, os coeficientes de dispersão a ser usados na Equação 1 são determinados por:

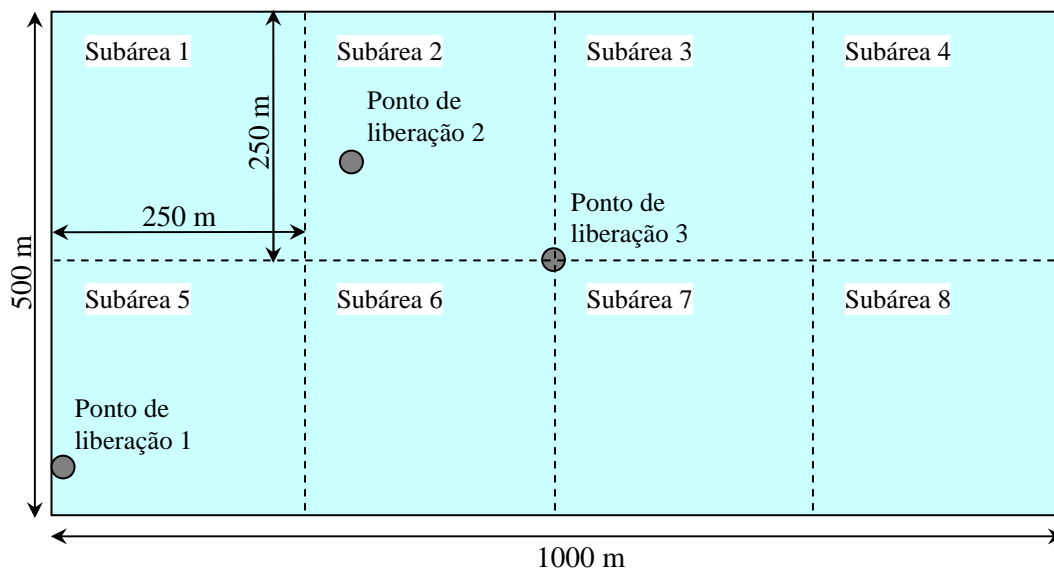
$$\sigma_y(x) = 0.16x(1 + 0.0001x)^{-1/2} \quad \text{Equação 4}$$

$$\sigma_z(x) = 0.12x \quad \text{Equação 5}$$

Para a distribuição dos detectores, a decisão tomada foi de dividir a área controlada da planta em oito subáreas de 250m x 250m, cada uma das quais deve conter um detector (Figura 3), atendendo uma norma interna da instalação laboratorial. Outros quesitos importantes que são levados em conta na definição do posicionamento dos detectores são:

- a proximidade entre detectores deve ser evitada, buscando uma distribuição mais homogênea e diversificação na identificação de diferentes cenários por um mesmo detector;
- os cenários mais prováveis de ocorrer e/ou que gerem plumas com maiores concentrações devem ter maior influência na solução final, ou seja, devem contribuir com maior peso na definição da distribuição dos detectores; e
- todos os cenários postulados deverão ser detectados, caso ocorram, pelo conjunto de detectores.

Diante do exposto, o problema que se apresenta é posicionar cada detector, em sua respectiva subárea, de maneira otimizada em relação ao conjunto de detectores, maximizando a capacidade de detecção de plumas provenientes de todos os cenários postulados. Um AG é usado como ferramenta de otimização.



**Figura 3. Vista esquemática da área controlada dividida em subáreas.**

## 5. RESULTADOS E DISCUSSÃO

Assumiui-se que, em qualquer dos cenários, as fontes estão emitindo liberações contínuas de 500g/s de um mesmo agente contaminante, a uma altura de 10m. As plumas são calculadas a uma altura de 1,70m (altura média de humano comum). Para os cálculos de otimização, a área controlada foi discretizada em regiões quadradas de 100m<sup>2</sup> e foi atribuída uma concentração do agente químico a cada uma dessas regiões, particularmente para cada cenário.

A medida da contribuição individual (aptidão) de um detector é feita considerando as concentrações relacionadas à sua posição, ponderadas pelas respectivas probabilidades de falha e frações de regime de vento. A aptidão do conjunto de detectores para uma pluma (ou cenário),  $F_{pluma}$ , traduz o somatório das contribuições individuais dos detectores e é definida como

$$F_{pluma} = \sum_{i=1}^n C_{(x_i, y_i)} \cdot P_{falha} \cdot v_{\%} \quad \text{Equação 6}$$

onde  $C_{(x_i, y_i)}$  é a concentração na posição  $(x_i, y_i)$  do detector “ $i$ ”,  $P_{falha}$  é a probabilidade de falha relativa ao ponto de liberação,  $v_{\%}$  é a fração do regime de vento e  $n$  é o número de detectores (neste estudo,  $n = 8$ ).

O processo de otimização foi conduzido por meio de busca exaustiva usando programa computacional comercial baseado em algoritmos genéticos. A função de avaliação ( $F_{obj}$ ) foi definida de modo a contemplar a contribuição ponderada de todas as plumas, a capacidade de um mesmo detector identificar um maior número de cenários e o grau de homogeneidade na distribuição dos detectores pela área controlada. Garante-se, desta forma, a busca por uma solução que otimize o desempenho do conjunto de detectores. A  $F_{obj}$  é dada, então, por

$$F_{obj} = \max \left\{ \prod_{j=1}^m (F_{pluma, j}) \cdot \sum_{j=1}^m (n_j \cdot F_{pluma, j}) \cdot \prod_{k=1}^s (d_{méd, k}) \right\} \quad \text{Equação 7}$$

onde  $F_{pluma, j}$  é a aptidão referente à pluma (ou cenário) “ $j$ ”,  $m$  é o número de cenários (neste estudo,  $m = 9$ ),  $n_j$  é o número de detectores que detectam a pluma “ $j$ ”,  $d_{méd, k}$  é a média das distâncias entre o detector da subárea “ $k$ ” e os detectores das subáreas adjacentes e  $s$  é o número de subáreas (neste estudo,  $s = 8$ ).


A melhor solução encontrada indica a colocação dos detectores nas coordenadas mostradas na Tabela 4.

**Tabela 4. Coordenadas dos detectores segundo a melhor solução.**

Subárea	1	2	3	4	5	6	7	8
x (m)	100	300	510	1000	60	500	560	1000
y (m)	260	410	350	500	50	10	250	10

A Figura 4 apresenta uma visão esquemática da área controlada, indicando a posição

dos detectores de acordo com a melhor solução encontrada pelo AG.



**Figura 4. Visão esquemática da área controlada indicando a posição dos detectores.**

Pela Figura 4, pode-se ver claramente que o resultado apresentado reflete a influência das condições do vento e favorece o posicionamento de detectores mais próximo aos pontos de maiores concentrações das plumas provenientes dos pontos de liberação 1, 2 e 3. Este fato é devido à imposição de ponderar a função de avaliação também pelas concentrações do agente químico ao longo da pluma.

Observa-se, também, a colocação de alguns detectores próximos às bordas da área controlada. No caso dos detectores 4, 6 e 8 (ver Figura 4), esse fato pode ser atribuído ao peso que se deu, na ponderação dos requisitos estabelecidos para a solução, à importância de se evitar a proximidade dos detectores. Dessa forma, nas subáreas onde a intensidade da pluma não era suficientemente grande, a tendência foi afastar os detectores o máximo possível.

Comportamento semelhante é observado nos limites das subáreas, onde há a presença de alguns detectores, como no caso do detector 1. Porém, aqui, esse posicionamento se deve à decisão de haver um detector em cada subárea, pois, caso contrário, a tendência era um posicionamento mais próximo aos pontos de liberação, como o detector 5.


Verifica-se, ainda, no caso do posicionamento dos detectores 2, 3 e 7, uma forte concordância com um trabalho de otimização anterior, onde se buscou uma solução com número mínimo de detectores [15]. As coordenadas são coincidentes, mesmo levando-se em conta que no presente trabalho outros fatores são abordados.

De um modo geral, a análise dos resultados mostra a influência da ponderação dos fatores envolvidos na orientação da busca da solução. Essa influência ressalta o quanto os requisitos estabelecidos e a tomada de decisão que antecede o processo de otimização devem ser criteriosos e equilibrados, pois nortearão a busca de soluções e conseqüentemente o resultado obtido.

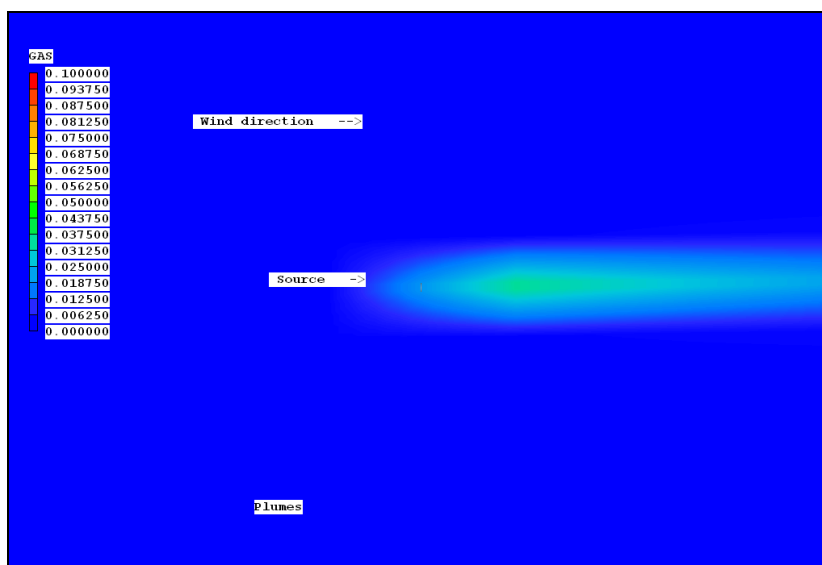
A solução obtida, que é plenamente compatível com os resultados previstos, atendeu a todas as restrições impostas e mostra a eficiência da metodologia proposta no tratamento de problemas deste tipo.



As Figuras 5 e 6 mostram exemplos de cálculos de desenvolvimento de plumas por Fluidodinâmica Computacional (CFD – Computational Fluid Dynamics). A Figura 5 apresenta a fase inicial do desenvolvimento de plumas para os três pontos de liberação, enquanto a Figura 6 mostra uma pluma a partir do ponto de liberação 3 em fase mais avançada.



**Figura 5. Desenvolvimento de plumas a partir dos pontos de liberação, por CFD.**



**Figura 6. Desenvolvimento de uma pluma a partir do ponto de liberação 3, por CFD**

## 6. CONCLUSÃO

Este trabalho apresentou uma abordagem de uma metodologia de apoio à decisão quanto ao posicionamento de detectores em ambiente sujeito à dispersão de agentes QBRN.

Um estudo teórico foi realizado para exemplificar a aplicabilidade e a eficiência da metodologia proposta.

A modelagem genética empregada teve como função definir as coordenadas dos detectores de modo a maximizar o desempenho do conjunto desses dispositivos na detecção de toda as possíveis plumas dos cenários postulados.

A partir da modelagem proposta, conclui-se que:

- uma convergência rápida é alcançada com uma malha relativamente grossa que é necessário para predições rápidas no caso de emergências;
- o problema pode ser postulado de várias maneiras, à medida que as variáveis podem ser modificadas para que um número grande de diferentes cenários possa ser simulado. Este trabalho mostra um caminho conveniente para selecionar o posicionamento ideal de um número determinado de detectores;
- as simulações de CFD mostram que uma dispersão no sentido contrário à direção do vento deveria ser considerada. Porém, modelagens com CFD, por serem mais precisas, requerem um maior tempo de processamento e muitas vezes este aumento do custo computacional não é justificável. Por isto, para o objetivo do trabalho, a escolha de modelagem mais simples é suficiente, pois aumenta a predição rápida da pluma de contaminante.

Como extensão do trabalho realizado, sugere-se considerar custos, tipos diferentes de detectores e agentes, tempo de resposta e cálculos de confiabilidade, além de ampliar o sistema estudado para um número maior de variáveis e de cenários. Podem ser usadas outras ferramentas de otimização em substituição ao AG.

## 7. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] BOWMAN, S., *Weapons of Mass Destruction: The Terrorist Threat*, Congressional Research Service, 2002.
- [2] DAVIS, L. E., LATOURRETTE, T., MOSHER, D. E., DAVIS, L. M., E HOWELL, R. D., *Individual Preparedness Response to Chemical, Radiological, Nuclear, and Biological Terrorist Attacks: A Quick Guide*, Santa Monica, CA, 2003. [http://www.rand.org/pubs/monograph\\_reports/2005/RAND\\_MR1731.1.pdf](http://www.rand.org/pubs/monograph_reports/2005/RAND_MR1731.1.pdf)
- [3] DWYER, A., ELDRIDGE, J., KERNAN, M., *Jane's Chem-Bio Handbook*, 2ª Edição, UK. 2003.
- [4] JONES, G. L., E EKSTRAND, L. E., *Customs Service: Acquisition and Deployment of Radiation Detection Equipment*, U.S. General Accounting Office, 2002 <http://www.gao.gov/>
- [5] TRUCANO, T. G., *Prediction and Uncertainty in Computational Modeling of Complex Phenomena*, Sandia National Laboratories, Albuquerque, N. Mex., USA, 1998.
- [6] MCDONALD, J. C., COURSEY, B. M., E CARTER, M., *Detecting Illicit Radiological Sources*, Physics Today, 36-41, Nov 2004. <http://homelandsecurity.pnl.gov/>
- [7] SUTTON, O. G., *Micrometeorology*, Mc Graw Hill Book Company, New York, 1953.
- [8] PASQUILL, F., *Atmospheric Diffusion*, Van Nostrand, London, 1962.
- [9] CHUNG, T. J., *Computational Fluid Dynamics*, Cambridge University Press, New York, USA, 2002.
- [10] HOLLAND, J. H., *Adaptation in Natural and Artificial Systems*. University of Michigan, Ann Arbor, MI, 1975

- [11] GOLDBERG, D.E., *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison-Wesley, USA, 1989.
- [12] MARTORELL, S., VILLANUEVA, J. F., CARLOS, S., et al., “RAMS + C informed decision-making with application to multi-objective optimization of technical specifications and maintenance using genetic algorithms”, *Reliability Engineering and System Safety*, v. 87, pp. 65-75, 2005.
- [13] GEN, M., YUN, Y., “Soft computing approach for reliability optimization: State-of-the-art survey”, *Reliability Engineering & System Safety*, v. 91/9, pp. 1008-1026, 2006.
- [14] DAMASO, V. C., ., Um Modelo de Otimização Integrada da Disponibilidade de Sistemas de Segurança Empregando Algoritmos Genéticos. Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 2006.
- [15] DAMASO, V. C., CABRAL, P. A. M., “A methodology to determining the optimal distribution of detectors to monitoring the dispersion of CBRN agents in the environment”, artigo submetido ao XL Simpósio Brasileiro de Pesquisa Operacional, João Pessoa, PB, Brasil, 2008 (em aprovação).