

# Descoberta automática de pontos de saída de criminosos em áreas urbanas: uma abordagem genética acoplada a um modelo de simulação baseado em inteligência coletiva

Adriano Melo, Vasco Furtado, André L.V. Coelho

Mestrado em Informática Aplicada (MIA) – Universidade de Fortaleza (UNIFOR)  
Av. Washington Soares, 1321, Bloco J, Sala 30 – 60811-905 – Fortaleza – CE – Brasil  
aanmelo@gmail.com, vasco@unifor.br, acoelho@unifor.br

**Abstract.** *Simulation of criminal activities in urban environments is an asset to decision makers on the police force. In order to perform preventive actions, the police needs to understand the behavior of criminals and their response to possible actions or configuration of patrols. However, simulation tuning is not trivial especially when it is presented as an optimization problem. In this paper, we describe a solution for the allocation of criminals into gateways (start points of criminals in the simulation) via the use of Genetic Algorithms (GAs). The use of GAs allows for the discovery, in an automatic way, of gateway configurations that, when used in the simulation, produce crime in the same distribution of real data. In the paper, we also show that, by making use of background knowledge, the system can provide suggestions of gateway configurations that are more plausible from the police expert viewpoint.*

**Resumo.** *Sistemas de simulação se apresentam como ferramentas úteis de suporte à tomada de decisão e têm sido usados no contexto da Segurança Pública permitindo aos peritos policiais a condução de experimentos controlados com um mínimo de risco. No entanto, a calibração desses sistemas não é trivial, particularmente quando ela se apresenta como um problema de otimização combinatória. Neste artigo, descrevemos nossa solução para um problema de alocação de criminosos a gateways (locais de saída de criminosos na simulação) através de algoritmos genéticos (AGs). O uso de um AG possibilita a descoberta, de forma automática, das configurações de gateways que, ao serem adotadas no modelo de simulação, venham a reproduzir da forma mais fidedigna possível os padrões de criminalidade observados na vida real. No artigo, avaliamos também como, ao se lançar mão de conhecimento do domínio, o sistema pode fornecer sugestões de configurações de gateways que sejam mais plausíveis sob o ponto de vista de um especialista em polícia.*

## 1. Introdução

Recentemente, uma extensa análise conduzida por [Cansado 2005] sobre dados reais de ocorrências de crimes relacionados a uma grande metrópole brasileira demonstrou que a distribuição espacial (geográfica) de crimes contra propriedade (como roubos, furtos e arrombamentos) obedece à Lei de Zipf [Zipf 1949]. Isso significa que muitas ocorrências de crimes urbanos acabam se concentrando em poucos locais de uma determinada área (conhecidos como *hot spots*) enquanto outros eventos se distribuem

por diversos outros locais. No contexto do policiamento preventivo, a identificação desses *hot spots*, bem como o aprendizado da dinâmica do fenômeno da criminalidade em diferentes cenários, torna-se bastante facilitada mediante o emprego de sistemas de simulação computacionais. Tais sistemas se apresentam como ferramentas úteis de suporte à tomada de decisão, permitindo a peritos policiais a condução de experimentos controlados com um mínimo de risco envolvido.

Este artigo descreve uma das etapas do nosso objetivo maior de produzir um modelo de simulação que permita a descoberta de estratégias mais eficientes para a prática do policiamento preventivo urbano. Visamos criar um modelo dinâmico para o fenômeno da criminalidade que reproduza experimentalmente como se dá a sua evolução em resposta a determinadas estratégias preventivas. Em estudos recentes, já demonstramos como é possível definir um modelo de simulação que gere crimes seguindo Lei de Zipf [Furtado et al. 2007]. Para tal finalidade, nós projetamos um modelo criminal baseado em sistemas multiagentes [Weiss 1999] e inteligência coletiva [Bonabeau et al. 1999], em que criminosos melhoram seus desempenhos mediante a criação de preferências ao longo da sua experiência em crimes. Tais criminosos foram modelados como agentes com a capacidade de exibir um comportamento auto-organizado, considerando suas atividades individuais (locais) e também as influências advindas de outros criminosos.

Não obstante os resultados animadores obtidos nesses recentes experimentos, alguns aspectos ainda carecem de serem mais bem investigados. Um deles diz respeito à definição dos pontos de saída dos criminosos durante as simulações. Esses pontos de saída, chamados aqui de *gateways*, referem-se aos locais de onde provavelmente surgem diariamente os criminosos antes de se dirigirem aos alvos em potencial com o intuito de cometerem crimes. Tais *gateways* compreendem, portanto, pontos de ônibus, estações de metrô, favelas, etc. O fato é que, embora nosso modelo de simulação seja dependente da configuração de saída dos criminosos a partir dos *gateways*, não existem dados reais ou modelos teóricos disponíveis que possam nos auxiliar na especificação correta dessa configuração. De fato, mediante entrevista com um perito policial responsável pela distribuição de equipes policiais, tornou-se evidente para nós que a escolha dos *gateways* seja um fator potencialmente importante para a determinação dos padrões de criminalidade em áreas urbanas, muito embora não se tenha ainda encontrado uma maneira formal de quantificar essa relevância na literatura especializada. Trata-se, portanto, de uma tarefa de calibração do nosso modelo de simulação de criminalidade, a qual, por sua vez, pode ser modelada como um problema típico de otimização combinatória: no caso, de alocação de criminosos a *gateways*. Uma vez que o espaço de busca desse tipo de problema tende a ser de alta dimensionalidade, decidimos confrontá-lo mediante o emprego de um algoritmo genético (AG) modificado [Mitchell 1996], já que essa técnica vem se mostrando bem adequada para lidar com tais situações.

Nosso objetivo, neste artigo, é o de caracterizar essa tarefa de calibração do nosso modelo de simulação e de apresentar passo-a-passo os componentes que integram o AG, avaliando o seu desempenho em casos de estudo controlados. Basicamente, o nosso intuito ao empregar uma solução baseada em AGs é o de possibilitar a descoberta, de forma automática, das configurações de *gateways* que, ao serem adotadas no modelo de simulação, venham a reproduzir da forma mais fidedigna possível os padrões de

criminalidade observados na vida real. Avaliamos aqui também como, ao se lançar mão de conhecimento do domínio, o sistema pode fornecer sugestões de configurações de *gateways* que sejam mais plausíveis sob o ponto de vista de um especialista. Como resultado, o que se espera em longo prazo é que a nossa ferramenta de suporte à decisão possa fornecer aos especialistas em policiamento preventivo listas interessantes de *gateways* em determinados cenários de estudo, subsidiando na sua tarefa de planejamento da alocação do efetivo policial.

O restante do artigo está estruturado da seguinte forma. Inicialmente, descrevemos o modelo básico de simulação e apresentamos o modelo comportamental dos criminosos que se fundamenta em conceitos de inteligência coletiva. Em seguida, caracterizamos formalmente o problema de seleção de *gateways* e descrevemos os componentes do algoritmo genético proposto. Os resultados experimentais obtidos e as comparações com dados reais são apresentados na quarta seção. Finalmente, a última seção traz considerações finais e perspectivas de trabalhos futuros.

## 2. Simulação criminal e patrulha policial

Nosso modelo de simulação possui basicamente três agentes: guardiões (policiais), alvos (pontos notáveis) e criminosos. Assumimos que cada um desses agentes pode ser completamente definido a partir de três propriedades:  $Ag = (O, D, R)$ . A propriedade  $O$  simboliza os aspectos ontológicos de um agente, ou seja, representa os seus conceitos e atributos. O componente  $D$  considera as regras e critérios adotados pelos agentes para decidir quais serão suas próximas ações ou mesmo como seu estado interno mudará. A propriedade  $R$  define como deveriam ser implementadas as atividades que o agente tem que exercer. Essas atividades são conseqüências diretas das decisões tomadas pelo componente  $D$ .

### 2.1 Equipe policial

Assumimos a existência de algumas equipes de policiais disponíveis, ficando cada uma responsável pelo monitoramento de algumas localidades do território urbano considerado. As equipes policiais executam somente a função de policiamento preventivo na simulação. Uma equipe policial  $j$  é modelada por um conjunto de quatro rotas de patrulhamento  $R_t(j) = \{P_{t1}, P_{t2}, \dots, P_{tm}\}$ ,  $t = 1, \dots, 4$ , sendo que cada rota está associada a um dos turnos diários — ou seja, manhã (de 6 h ao meio-dia), tarde (de meio-dia às 18 h), noite (de 18 h à meia-noite) e madrugada (de meia-noite às 6 h). Por sua vez, cada elemento  $P_{ti}$  de uma rota é definido por um par  $P_{ti} = (T_{gi}, \Delta_{ii})$ . Nessa definição,  $T_{gi}$  indica um dos possíveis alvos a serem patrulhados (ver próxima subseção), enquanto  $\Delta_{ii}$  denota o intervalo de tempo em que a equipe policial permanecerá fixa nesse alvo. Deve-se ressaltar que, para a execução de uma simulação, esse conjunto de rotas deve ser definido previamente e não se modificará em resposta às ações dos criminosos. Assumimos também que não há diferenciação, em termos de habilidades, entre os policiais distribuídos em diferentes equipes. Mais ainda: diferentes equipes podem ser associadas a diferentes tamanhos de rotas em cada turno, as quais podem se sobrepor e/ou compartilhar alvos.

## 2.2 Pontos notáveis

Os locais a serem patrulhados são chamados de pontos notáveis, que se diferenciam com relação ao tipo de estabelecimento comercial ou entretenimento que representam: farmácias, bancos, postos de gasolina, lotéricas, praças ou *shoppings*. Para a representação desses alvos, utilizamos um mapa geo-referenciado do bairro da Aldeota em Fortaleza. Não são modelados aqui pontos notáveis móveis, pois estamos nos concentrando em crimes contra propriedade. Pontos notáveis possuem um estado de vulnerabilidade que pode estar ativo ou inativo em um certo momento. Os pontos notáveis considerados vulneráveis são passíveis de serem percebidos pelos criminosos; caso contrário, não farão parte do conjunto de possíveis alvos a serem eventualmente selecionados por eles. Cada alvo tem uma probabilidade inicial de vulnerabilidade, que segue uma distribuição temporal real por tipo de alvo. A partir desse “parâmetro de controle”, torna-se possível reproduzir um ritmo de crimes por tipo em consonância com aquele observado na realidade. É certo que a distribuição temporal desses crimes varia por dia e horário, e, portanto, tentamos modelar essa variação ocorrendo nos quatro turnos de seis horas mencionados anteriormente. Para cada turno, foi fixado um valor  $\lambda$  que define o ritmo de ocorrência de crimes para cada tipo de alvo. Desse modo, uma ocorrência de roubo a banco em horário comercial deverá assumir um valor de  $\lambda$  quatro vezes maior do que o mesmo tipo de ocorrência no período da noite ou madrugada.

## 2.3 Criminosos

Este é o conjunto de agentes que representam os criminosos e frequentemente tentam cometer crimes. Cada criminoso possui uma visão limitada do ambiente, que é medida em termos de número de quarteirões. Por exemplo, com uma visão de 200 metros, se cada quarteirão tem em média 100 metros de comprimento, o criminoso poderá perceber o que ocorre em um raio de dois quarteirões ao seu redor. Os criminosos têm um ponto de saída. Cada ponto de saída representa locais de onde os criminosos provavelmente saem para cometer seus crimes diariamente; por exemplo, suas residências, estações de metrô, paradas de ônibus, etc. Assumimos que, ao final de cada dia, cada criminoso sempre retornará para seu domicílio, algo que independe do número de crimes que ele cometeu por dia. A seleção de alvos é probabilística (veja a Subseção 2.5 para a formalização da estratégia adotada) com relação a três fatores: vulnerabilidade do alvo, distância entre o criminoso e o alvo, e experiência do criminoso. Tendo probabilisticamente selecionado o próximo alvo, o tempo gasto para ele conseguir alcançá-lo é baseado na velocidade com que o criminoso se move e na distância para com o alvo. O menor período de tempo gasto para chegar ao próximo alvo, considerando todos os criminosos ao mesmo tempo, é considerado como um tempo de referência, de forma que, aos criminosos, é permitido somente se mover durante esse período de tempo a cada passo (*tick*) de simulação. Deve-se lembrar que somente os alvos vulneráveis serão considerados no processo de seleção. Finalmente, a decisão de cometer ou não um crime é tomada com base na existência de uma ou mais equipes policiais dentro do raio de visão do criminoso. Se o criminoso decidir não cometer um crime, então ele selecionará um novo alvo, considerando o local atual. Caso contrário, assume-se que um crime foi cometido e que outro alvo será selecionado.

## 2.4 Capacidade de aprendizagem e relacionamento social entre os criminosos

O comportamento de um criminoso tem um componente de aprendizagem que explora a sua própria experiência e a dos outros agentes com os quais interage em relação aos alvos em potencial. A taxa de sucesso individual de um criminoso é calculada, a todo momento, como sendo a razão entre a soma do número de ocorrências de crimes bem-sucedidas ao longo de sua vida e o número total de tentativas praticadas. Os criminosos formam comunidades em que são compartilhadas sugestões (dicas) a respeito dos pontos notáveis. Assumimos que os agentes de uma mesma comunidade se comunicam entre si ao final de cada dia. Devido à interconexão das comunidades, essas sugestões poderão ser transmitidas a outros criminosos em outras comunidades, e a velocidade com a qual essa disseminação acontece dependerá diretamente da topologia da rede de comunidades. Neste artigo, em particular, lançamos mão da topologia conhecida como *small-world*. Consideramos essa topologia, uma vez que trabalhos recentes em análise de redes sociais enfatizam a sua adequação para fins de representação dos variados tipos de relações humanas [Buchanan 2002], ao tempo em que trabalhos de criminologia vêm identificando estruturas de *small-world* em diferentes casos envolvendo redes de criminosos reais [Kaza et al. 2005].

## 2.5 Comportamento do agente criminoso baseado em inteligência coletiva

Em nosso modelo, cada criminoso tem três possibilidades de ações: cometer o crime, não cometer o crime e mover-se para o local do crime. Para selecionar o próximo alvo de ataque, ele se utiliza de uma equação probabilística similar àquela adotada em sistemas de inteligência coletiva baseados em formigas [Bonabeau et al. 1999] — vide Eq. (1). Analisando essa equação, temos que  $p_{cn}$  representa a probabilidade do agente criminoso  $c$  selecionar o alvo  $n$  para ataque:

$$p_{cn} = \frac{[\tau_{cn}]^\alpha \times [\varphi_{cn}]^\beta}{\sum_{\forall p \in N} [\tau_{cp}]^\alpha \times [\varphi_{cp}]^\beta} \quad (1)$$

Na Eq. (1),  $\tau_{cn}$  denota a experiência adquirida pelo criminoso  $c$  com relação ao alvo  $n$ , ao passo que  $N$  é o conjunto de todos os alvos considerados correntemente pelo criminoso  $c$  (ou seja, com vulnerabilidade ativa). O outro parâmetro,  $\varphi_{cn}$ , é o inverso da distância entre o local onde o criminoso  $c$  se encontra e o alvo  $n$ ; nós assumimos que o criminoso tem o conhecimento necessário para localizar os alvos no mapa.

Evidências empíricas mostram que muitos criminosos não se distanciam muito para cometer seus crimes. A maioria das ocorrências contra propriedades é cometida em bairros próximos, mas não tão perto de suas residências. Desse modo, decidimos modelar a probabilidade de um criminoso se locomover a um certo local como o inverso da distância que ele deverá percorrer; isso indica que pontos mais próximos de um criminoso têm mais chance de serem selecionados. Os parâmetros  $\alpha$  e  $\beta$  na Eq. (1) são usados para balancear a importância de  $\tau_{cn}$  sobre  $\varphi_{cn}$ . Note que  $\varphi_{cn}$  é o inverso da distância; assim, quando  $\beta$  for incrementado, o fator de aprendizagem torna-se mais preponderante. A Eq. (1) é aplicada a todos os alvos vulneráveis naquele momento e essa decisão é feita para a escolha do próximo ataque. Quando o ponto notável for escolhido, o criminoso tentará cometer efetivamente o crime. Como resultado desse processo de escolha de alvos e de realização de ataques por parte de um criminoso  $c$ ,



podem ser obtidas duas estatísticas:  $CT_{cn}$  e  $CT_c$ . A primeira corresponde ao número de tentativas de crimes no último dia em relação a um alvo específico  $n$ ; já a segunda representa o cumulativo (global) para todos os alvos do ambiente. Cada uma dessas estatísticas pode ser subdividida em: (i) tentativas bem-sucedidas (em que os crimes efetivamente ocorreram), representadas por  $CO_{cn}$  e  $CO_c$ , respectivamente; e (ii) tentativas mal-sucedidas (as quais foram, de algum modo, prevenidas por policiais).

Uma descrição mais detalhada dos fatores de aprendizado individual e social pode ser obtida em [Furtado 2007], sendo que sua compreensão não é crucial para o entendimento do restante deste artigo. Suficiente é afirmar que o fator social tem se mostrado relevante para que o modelo de simulação adotado gere crimes de acordo com a distribuição Zipf.

### 3. Formulação do problema de seleção de *gateways* e especificação do algoritmo genético

Conforme já mencionado, nosso modelo de simulação criminal vem sendo construído tendo em vista a reprodução das distribuições espacial e temporal de ocorrências de crimes conforme observadas em cenários reais. Neste artigo, nosso foco é o de investigar o impacto exercido pela escolha dos pontos de saída dos criminosos sobre a qualidade exibida pelo modelo de simulação quando da tentativa de reproduzir, da forma mais fiel possível, tais distribuições. Para tanto, modelamos essa tarefa de configuração dos *gateways* como um problema de otimização combinatória, i.e., de alocação de criminosos a *gateways*, o qual é descrito a seguir.

Sejam  $G = \{G_i, i=1, \dots, N_g\}$  o conjunto de *gateways* e  $C = \{C_j, j=1, \dots, N_c\}$  o conjunto de criminosos disponíveis no ambiente de simulação. O intuito é o de alocar cada  $C_j$  a um dos  $G_i$ , de tal modo que uma certa medida de qualidade  $F$  referente ao modelo de simulação seja maximizada<sup>1</sup>. Nesse processo de alocação, qualquer *gateway* é passível de ser atribuído a um criminoso, sendo que nenhum criminoso pode ficar sem um *gateway* associado. Além disso, é válido afirmar que mais de um  $C_j$  pode estar associado a um mesmo  $G_i$ , muito embora não tenhamos imposto nenhuma restrição sobre o número máximo de criminosos por *gateway*. Contudo, não é permitido atribuir um dado  $C_j$  a mais de um  $G_i$  ao mesmo tempo. Como já foi detectado que vários problemas de alocação são de natureza reconhecidamente NP-difícil, é válido se conjecturar que, para um dado cenário de simulação, exista uma quantidade elevada (provavelmente exponencial) de possibilidades de alocação de criminosos a *gateways*, incorrendo em espaços de busca de alta dimensionalidade. Para lidar com esse problema, decidimos lançar mão de um algoritmo genético modificado [Mitchell 1996], cujos componentes conceituais são descritos a seguir.

Cada cromossomo (indivíduo) representa uma possível configuração de *gateways*, ou seja, uma possível alocação de criminosos a *gateways*. Para tanto, a

---

<sup>1</sup> Em um problema de alocação típico envolvendo agentes e tarefas [Pentico 2007], cada atribuição de uma tarefa a um agente tem um custo associado, de modo que o que se almeja é um conjunto de atribuições que cubra todas as tarefas e que ao mesmo tempo incorra em um custo total mínimo. No nosso caso, os custos de alocação são unitários e o objetivo é maximizar a qualidade do modelo de simulação.

codificação adotada é do tipo inteira, sendo que cada um dos  $N_c$  genes de um cromossomo recebe como valor um índice  $i$  ( $i=1, \dots, N_g$ ) representando um dos possíveis *gateways*. Destarte, a ordem de grandeza do espaço de busca do AG é de  $O(N_g^{N_c})$ . Quando da avaliação de cada indivíduo, o AG interage com o ambiente de simulação multiagente, repassando-lhe a configuração dos *gateways* como parâmetro de entrada do modelo de simulação. Ao final da execução da simulação, o AG recebe o valor de aptidão (*fitness*) relativo ao indivíduo. Para assumir o papel de função de aptidão  $F$ , lançamos mão do teste do  $\chi^2$  [Bussab 2003], de modo a se comparar a distribuição espacial produzida pela instância do modelo de simulação associada a esse cromossomo com aquela obtida a partir da análise de dados reais. Mais precisamente: ao final da execução de cada simulação, é possível se comparar tanto a frequência de ataques bem sucedidos aos pontos notáveis como o número total de ocorrências produzidas pela simulação com aqueles valores obtidos na realidade. Em suma: o resultado da aplicação desse teste nos fornece uma medida quantitativa para indicar quão bem o modelo de simulação ajustado com uma dada configuração de *gateways* reproduz o fenômeno da criminalidade real. Dada a natureza estocástica do processo de simulação, cada cromossomo deverá ser avaliado um número  $N_s$  de vezes ( $N_s > 1$ ), tendo o seu valor de *fitness* final calculado como a média dos valores de *fitness* obtidos nas  $N_s$  avaliações. Os operadores de variação adotados foram *crossover* de um ponto e mutação simples, ao passo que o método da roleta foi empregado como operador de seleção e substituição.

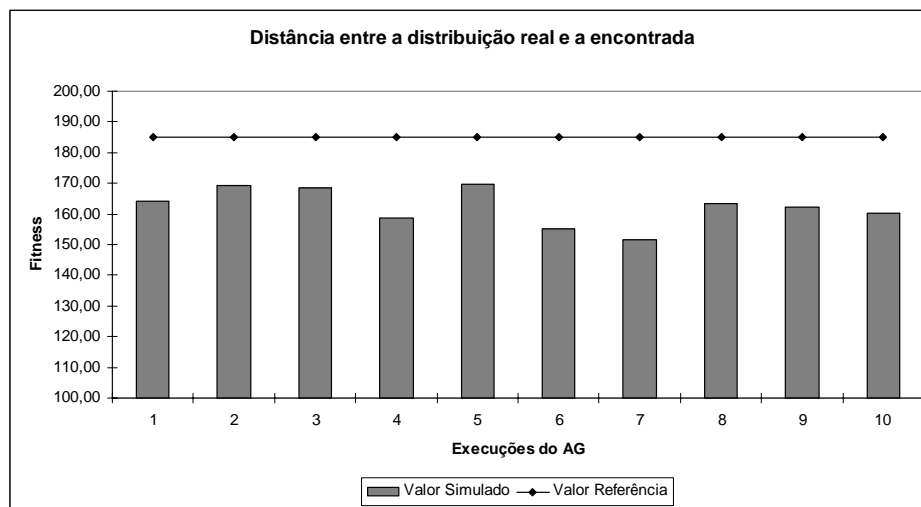
#### 4. Avaliação e resultados

Em nossos experimentos, utilizamos uma população de 50 indivíduos e um número máximo de 50 gerações. A taxa de *crossover* foi de 95% e a de mutação foi de 5%. Os valores de  $N_s$ ,  $N_c$  e  $N_g$  foram 5, 16 e 33, respectivamente, o que deu origem a um espaço de busca de grandeza  $\approx O(10^{24})$ .

Nossa primeira avaliação visou identificar se o AG conseguiria encontrar configurações de *gateways* que levassem o modelo de simulação da criminalidade a produzir crimes conforme a realidade. Para isso, executamos o AG 10 vezes e, para cada configuração de *gateways* obtida, verificamos se os resultados se aproximavam dos dados reais. Em verdade, essa tarefa consistiu em avaliar a evolução do AG, visto que a proximidade ou não para com os dados reais é capturada na função de *fitness*. Os resultados indicaram que, com uma população inicial de 50 e com 50 gerações, o AG conseguiu convergir para uma configuração de *gateways* que produz crimes próximos à distribuição real. Na Figura 1, apresentamos um gráfico comparativo entre os valores de *fitness* dos melhores cromossomos de cada execução do AG e um valor de referência. Esse valor de referência é um limiar que demarca até onde as distribuições podem ser consideradas equivalentes. Esse valor foi obtido com base na tabela do teste do  $\chi^2$  [Bussab 2003] e no desvio-padrão dos resultados das simulações. Nessa figura, verifica-se que todos os valores se encontram abaixo do valor máximo permitido, indicando que a distribuição encontrada pode ser considerada equivalente à distribuição real.

A segunda avaliação consistiu em verificar quão informativas seriam as configurações de *gateways* descobertas pelo AG. Nossa estratégia foi a de simular a criminalidade como se tivéssemos à disposição a informação de qual configuração de

*gateways* seria a real — obviamente, não há como se obter tal informação na prática. Portanto, nosso intuito foi o de analisar a proximidade das configurações de *gateways* descobertas pelo AG daquela que seria a “supostamente real”, aqui denominada  $G_{real}$ . Os resultados obtidos com 10 execuções, seguindo-se as mesmas configurações dos parâmetros de controle do AG em dois cenários distintos, foram os seguintes. No primeiro cenário (Cenário #1), para a definição de  $G_{real}$ , os 16 criminosos foram alocados aleatoriamente a 14 *gateways* (dois *gateways* eram pontos de saída de mais de um criminoso). Os resultados mostraram que, em média, o AG conseguiu encontrar configurações contendo 40,60 % dos pontos de  $G_{real}$ .



**Figura 1 – Grau de proximidade entre as configurações de *gateways* obtidas via simulador e aquelas oriundas do caso real**

Simulamos, então, um cenário mais complexo (Cenário #2), em que agrupamos os criminosos em quatro *gateways* diferentes, de onde partiam quatro criminosos cada. Os resultados mostraram que, em média, o AG conseguiu encontrar configurações de *gateways* contendo apenas 22,22% dos pontos de  $G_{real}$ .

Mediante interação com especialistas no domínio, identificamos a possibilidade de incrementar esse resultado, uma vez que na vida real nem todos os *gateways* são considerados igualmente plausíveis para um certo ambiente. Desse modo, realizamos novos experimentos incluindo essa informação de plausibilidade quando da geração da população inicial do AG. Desse modo, a probabilidade de se gerar indivíduos do AG que contivessem *gateways* definidos como mais plausíveis pelo especialista foi incrementada. Isso foi feito mediante a atribuição de um peso (variando entre 0 a 1) para cada *gateway*. Os resultados obtidos mostraram que a taxa de acerto obtida em média pelo AG (no sentido da proximidade das configurações produzidas com aquela relativa a uma distribuição supostamente real) foi bem maior. Nos cenários supracitados, chegou-se a uma concordância na faixa de 75%.

Outra informação que nos foi repassada por especialistas refere-se ao fato de que, para efeito de policiamento preventivo, não há muita diferença, em termos estratégicos, entre se identificar exatamente os *gateways* de  $G_{real}$  ou se identificar outros quaisquer que estejam próximos a eles. A razão por trás disto é que o policiamento preventivo ocorre com base em zonas de enfoque; assim, a informação de



que uma determinada zona do território (que não seja muito grande) seja convergência de saída de criminosos é suficiente para auxiliar no planejamento tático. Dessa forma, relaxamos o problema de se descobrir *gateways* idênticos aos de  $G_{real}$ , passando a considerar como válidos também aqueles que estivessem a uma distância de até dois quarteirões. Sob essas condições, a taxa de concordância atingida pelo AG entre os *gateways* encontrados e aqueles supostamente reais melhorou para 75% no Cenário #1 e para 78,12% no Cenário #2. Isso significa que o AG conseguiu encontrar *gateways* substitutos àqueles reais, que estivessem dentro das suas zonas de ataque. Quando se conduziu essa mesma análise com o uso de conhecimento de plausibilidade do especialista, os resultados foram ainda melhores, atingindo as taxas de 87,5% e 81,25% para os Cenários #1 e #2, respectivamente.

## 5. Trabalhos relacionados

Os trabalhos que visam realizar simulações de fenômenos criminológicos lançam mão de técnicas tradicionais de calibração de seus modelos [Liang and Liu 2001], [Xue 2006]. Isso ocorre em grande parte pelo fato de que especialistas não possuem modelos de simulação que contemplem um grau de refinamento tão detalhado como o que estamos investigando. Geralmente, esse processo de calibração não é modelado formalmente como um problema de otimização; outras vezes, é ignorado. Em [Calvez 2005], é feita uma análise genérica de como um AG pode ser usado para a calibração de sistemas multiagentes. Os autores concluem que AGs podem ser uma ótima ferramenta para auxiliar na varredura de parâmetros de uma simulação uma vez que possibilita a medição do impacto que uma variável pode exercer sobre outra. No nosso caso, embora estejamos nos concentrando em um único parâmetro, ele por si só exige considerável tempo de análise, pois, como já dissemos, se trata de otimização combinatória dos valores que este parâmetro pode assumir. Seguindo uma perspectiva complementar àquela explorada neste trabalho, em [Reis 2006], a integração entre AGs e simulação multiagente foi explorada com o intuito de se identificar, automaticamente, rotas efetivas de policiamento preventivo.

## 6. Conclusões e trabalhos futuros

Este artigo descreve nossa abordagem de integração de um AG com simulação multiagente para a descoberta de pontos de saída de criminosos (*gateways*) em ambientes urbanos. Essa tarefa de configuração de *gateways*, além de servir para calibrar o nosso modelo de simulação de criminalidade, pode vir a auxiliar peritos policiais em seus processos de tomada de decisão relativa ao patrulhamento preventivo, pois auxilia na identificação de potenciais zonas de origem de criminosos. Neste trabalho, avaliamos como as respostas produzidas pelo AG podem ser incrementadas, em termos do seu grau de plausibilidade, lançando mão de conhecimento disponível do domínio. Com efeito, essa estratégia de se considerar conhecimento a priori sobre o domínio quando da geração da população inicial do AG abre a possibilidade de se investigar outras funções de relevância associadas aos *gateways*. Por exemplo, poderiam ser definidas funções alternativas que calculassem a relevância (peso) de cada *gateway* a partir de outros aspectos: (i) a proximidade para com os pontos notáveis; ou (ii) a quantidade de rotas de ônibus que circulassem pelo local; ou ainda (iii) a taxa de

circulação de pessoas pela região. Experimentos nesse sentido deverão ser objeto de trabalhos futuros.

## Referências

- Calvez, B. e Hutzler, G. (2005), Automatic tuning of agent-based models using genetic algorithms, Procs. of the 6th International Workshop on Multi-Agent-Based Simulation (MABS), pp. 41-57.
- Cansado, T. M. L. (2005), Alocação e despacho de recursos para combate à criminalidade. Dissertação de mestrado, UFMG, Belo Horizonte.
- Bonabeau, E., Dorigo, M. e Theraulaz, G. (1999), Swarm Intelligence: From Natural to Artificial Systems. Santa Fe Institute Studies in the Sciences of Complexity Series. Oxford Press.
- Buchanan, M. (2002), Nexus: Small Worlds and the Groundbreaking Science of Networks. W. W. Norton, New York.
- Bussab, W. O. e Morettin, P. A. (2003), Estatística Básica, Saraiva.
- Furtado, V., Melo, A., Coelho, A. L. V. e Menezes, R. (2007), A crime simulation model based on social networks and swarm intelligence, Procs. of 22nd ACM Symposium on Applied Computing (SAC 2007), pp. 56-57, Korea.
- Furtado, V. e Vasconcelos E. (2006), A multiagent simulator for teaching police allocation. AI magazine 27(3), pp. 63-74.
- Kaza, S., Xu J. and Marshall B. e Chen H. (2005), Topological analysis of criminal activity networks in multiple jurisdictions, Procs. of the National Conference on Digital Government Research, ACM International Conference Proceeding Series, Vol. 89, pp. 251-252.
- Liang, J., Liu, L. e Eck, J. (2001), Simulating crimes and crime patterns using cellular automata and GIS. Department of Geography and Division of Criminal Justice. University of Cincinnati, Cincinnati.
- Mitchell, M. (1996), An Introduction to Genetic Algorithms, MIT Press.
- Pentico, D. W. (2007), Assignment problems: A golden anniversary survey. European Journal of Operational Research 176(2): 774-793.
- Reis, D., Melo, A., Coelho, A. L. V. e Furtado, V. (2006), GAPatrol: An evolutionary multiagent approach for the automatic definition of hotspots and patrol routes, in: J. S. Sichman; H. Coelho; S. Oliveira (Eds.), Procs. of IBERAMIA/SBIA 2006, Lecture Notes in Artificial Intelligence (LNAI) 4140, pp. 118-127.
- Xue, Y. and Brown, D. (2006), Spatial analyses with preference specification of latent decision makers for criminal event prediction. Decision Support Systems, 41(3), pp 560-573.
- Weiss, G. (1999), Multiagent Systems: A Modern Approach to Distributed Artificial Intelligence, MIT Press.
- Zipf, G. K. (1949), Human Behaviour and the Principle of Least-Effort, Addison-Wesley, Cambridge MA.