

CALIBRAÇÃO DE REDES VIÁRIAS URBANAS MICROSSIMULADAS COM O USO DE ALGORITMOS GENÉTICOS

André Luis Medeiros

Manoel Mendonça de Castro Neto

Carlos Felipe Grangeiro Loureiro

Universidade Federal do Ceará

Departamento de Engenharia de Transportes

José Elievam Bessa Júnior

Escola de Engenharia de São Carlos, Universidade de São Paulo

Departamento de Engenharia de Transportes

RESUMO

Os principais *softwares* de microsimulação de tráfego requerem a calibração de diversos parâmetros. Este artigo busca avaliar a aplicabilidade de algoritmos genéticos à calibração de uma rede viária urbana localizada na cidade de Fortaleza, cujos altos graus de adensamento e reticularidade estão presentes em outras cidades brasileiras. Foram avaliados os efeitos dos parâmetros e operadores de um algoritmo genético na calibração de 10 parâmetros do microsimulador VISSIM. Os resultados indicam que a variação na configuração do algoritmo genético não afetou significativamente os resultados da calibração. A simulação com todos os parâmetros em valores *default* resultou num erro percentual absoluto médio de 29%. Após a inserção dos valores de dois parâmetros coletados em campo e da inclusão do transporte público, o erro reduziu para 13%. Após a calibração, o erro diminuiu para 8%. O erro de validação da rede foi de 13%.

ABSTRACT

The main traffic microsimulation packages require the calibration of various parameters. This article aims to evaluate the applicability of genetic algorithms to the calibration of an urban reticular, high-density network located in the city of Fortaleza, similar to networks found in other Brazilian cities. The effects of the parameters and operators of genetic algorithms in the calibration of 10 parameters of VISSIM microscopic simulator were investigated. The results indicate that variations in the configuration of the genetic algorithms did not affect the calibration results significantly. The simulation with all VISSIM parameters under *default* values resulted in a MAPE of 29%. After inserting the values of two parameters collected in the field, as well as the inclusion of public transport, the error was reduced to 13%. After calibration of the parameters, the error decreased to 8%. The validation error of the network was 13%.

1. INTRODUÇÃO

A busca e a análise de possíveis alternativas para solucionar, ou pelo menos minimizar, o problema da baixa fluidez do tráfego nas grandes cidades brasileiras tem se tornado uma grande preocupação para a gestão pública, uma vez que o impacto da saturação nas malhas viárias reflete diretamente, dentre outros fatores, na diminuição da produtividade e na qualidade de vida da população. Devido a crescente complexidade dos problemas de tráfego aliada a maior disponibilidade de recursos computacionais existentes, modelos de simulação computacional estão sendo cada vez mais utilizados por engenheiros e analistas para auxiliar no planejamento e operação dos sistemas de transporte e tráfego urbanos (Barceló, 2010).

Os simuladores computacionais de tráfego têm como função representar, num nível satisfatório, o comportamento dos veículos e facilitar a análise das várias alternativas destinadas a melhorar o comportamento do fluxo veicular, sem a necessidade de intervenções na malha viária em estudo, evitando transtornos aos usuários e minimizando custos operacionais. Além da fluidez, os pacotes de microsimulação têm sido empregados também em análises de segurança viária (Zhang *et al.*, 2013) e em emissão de poluentes (Song *et al.*, 2012). Conforme defendido por Hourdakakis *et al.* (2003), para que um simulador possa fornecer resultados confiáveis sobre o sistema de tráfego estudado é fundamental que seus parâmetros estejam devidamente calibrados e validados, e ainda afirmam que a calibração de

simuladores de tráfego é frequentemente realizada por tentativa e erro, onde o êxito do processo é dependente da experiência do usuário. Este processo, porém, quando não automatizado, revela-se lento e pouco eficiente.

O principal objetivo deste artigo é avaliar a aplicabilidade de algoritmos genéticos (AG) para a calibração de redes urbanas reticuladas microssimuladas. Como objetivos específicos estão: apresentar um método para o desenvolvimento de tais redes; analisar o efeito de etapas de codificação e calibração na qualidade do modelo; e analisar o efeito de parâmetros do AG na calibração.

2. CALIBRAÇÃO DE MICROSSIMULADORES

Os pacotes de simulação microscópica contêm vários parâmetros que são usados para descrever o comportamento das unidades condutor/veículos. De forma geral, estes parâmetros estão relacionados aos modelos de carro-seguidor (*car-following*), mudança de faixa, e aceitação de brecha, além de parâmetros específicos dos arcos e das interseções da rede. Cada parâmetro possui seu valor *default* escolhido, e que geralmente refletem os locais onde os simuladores foram desenvolvidos. Porém para que um simulador possa reproduzir de forma satisfatória o tráfego em análise, faz-se necessário um ajuste destes valores. (Toledo e Koutsopoulos, 2004; Hourdakis *et al.*, 2003).

O ajuste dos valores dos parâmetros pode ser feito basicamente de duas formas. Na primeira, a escolha do valor do parâmetro baseia-se em estudos anteriores ou em coleta de dados em campo. Nestes casos, o modelador informa ao programa o valor do parâmetro a ser utilizado. A segunda forma é por meio de calibração, que consiste em testar diversos valores dos parâmetros de forma a minimizar as diferenças dos valores das medidas de desempenho simuladas e observadas em campo (Kim e Rilett, 2001; Hollander e Liu, 2008). Para maior clareza e distinção da forma como os valores dos parâmetros são obtidos, os autores do presente trabalho sugerem que na primeira forma de ajuste os parâmetros sejam denominados “dados de entrada”, e que na segunda eles sejam chamados de “parâmetros de calibração”.

Devido ao grande número e variedade de parâmetros dos atuais modelos de microssimulação, bem com a infinidade de aplicações e finalidades que os quais podem ser empregados, não há na literatura um método universal para calibração e validação desses modelos. No entanto, pesquisadores têm discutido os requisitos gerais de um procedimento para calibração e validação de simuladores de tráfego (Hellinga, 1998; Barceló, 2010).

Com a evolução dos modelos microscópicos e um crescente grau de detalhamento, o número de parâmetros de calibração pode ser muito elevado. Como exemplo, o software VISSIM versão 5.30 traz 30 parâmetros comportamentais passíveis de calibração, dos quais 10 são apenas de *car-following*. Segundo Ayala (2013), o microssimulador Aimsun versão 7.0 possui 60 parâmetros passíveis de calibração, dos quais 24 foram escolhidos pela autora como particularmente importantes. Quando o número de parâmetros de calibração é elevado, pode-se reduzir o espaço de busca por meio do conhecimento da relação de dependência entre os parâmetros. Por exemplo, motoristas com tempo de reação elevado possuem maior tendência a desacelerar para evitar colisões. Assim, algumas combinações improváveis de valores de parâmetros podem ser descartadas do processo de calibração (Kim e Mahmassani, 2011).

Durante a revisão dos vários métodos de otimização existentes e possíveis de serem utilizados na calibração de microssimuladores, percebeu-se uma considerável quantidade de trabalhos que constatarem a eficiência da utilização dos algoritmos genéticos na calibração de parâmetros de simuladores de tráfego CORSIM (Bessa Jr. e Setti, 2012), PARAMICS (Ma e Abdulhai, 2002; Ma *et al.*, 2007), VISSIM (Park e Qi, 2005), TWOPAS (Mon-Ma, 2008) e INTEGRATION (Bessa Jr. *et al.*, 2008). Em todos esses estudos, os resultados obtidos a partir das simulações realizadas com os valores dos parâmetros otimizados pelo algoritmo genético foram melhores do que os obtidos com os valores *default*. Na literatura há uma lacuna acerca da aplicabilidade deste tipo de algoritmo para calibração de redes viárias urbanas reticuladas e adensadas, características encontradas em diversas cidades brasileiras.

3. ALGORITMOS GENÉTICOS

Os algoritmos genéticos (AG's) constituem uma técnica de busca e otimização, inspirada no princípio darwiniano da seleção natural e reprodução genética (Pacheco, 1999). Os AG's utilizam um conjunto de soluções iniciais, denominadas cromossomos, que através de diversas operações evoluem até que se encontre uma solução que melhor atenda a algum critério específico de avaliação. Para que isto ocorra, a cada geração os cromossomos (soluções) são avaliados por uma função chamada *fitness* que mede o seu nível de aptidão, ou seja, quão boa uma determinada solução se apresenta para o problema em questão. Os cromossomos que apresentarem a melhor *fitness* são selecionados para iniciarem uma próxima geração utilizando operadores como seleção, *crossover*, predação e mutação. Sendo assim, espera-se que através da utilização desses operadores, o conjunto de soluções de cada geração seja aprimorado, até que se obtenha a uma solução que atenda ao critério de parada escolhido.

3.1. Parâmetros dos Algoritmos Genéticos

O desempenho dos algoritmos genéticos está diretamente relacionado à escolha adequada dos parâmetros de controle e dos operadores genéticos utilizados. O equilíbrio entre a capacidade de exploração de novas regiões do espaço e a intensificação da busca em regiões já visitadas deriva, principalmente, da escolha dos seguintes parâmetros: tamanho da população, número de gerações, taxa de cruzamento ou de *crossover* e taxas de predação e mutação. Abaixo seguem algumas definições desses parâmetros:

- Tamanho da população: A população é formada por um determinado número de indivíduos, ou seja, as possíveis soluções dentro do intervalo limitado pré-estabelecido para o problema em pauta. Um número muito pequeno de indivíduos acarreta um espaço de busca reduzido podendo conduzir o algoritmo a um mínimo local, enquanto que um número muito elevado de indivíduos faz com que a convergência do algoritmo ocorra mais lentamente, pois o algoritmo irá explorar mais o campo de busca; conseqüentemente, o número de cálculos de *fitness* por geração pode resultar num tempo computacional extremamente demorado;
- Número de gerações: É o número de iterações completas a partir do qual o algoritmo genético gera uma nova população. A literatura deixa claro que o tamanho da população e o número de gerações dependem da complexidade do problema e devem ser determinados experimentalmente. Deve-se lembrar que a combinação do número de indivíduos com o número de gerações definem diretamente o tamanho do espaço de busca a ser coberto.

Outros parâmetros, chamados operadores genéticos, têm a função de buscar novas soluções na população, tais como elitismo, as taxas de predação e mutação. Segue a descrição desses parâmetros:

- **Elitismo:** Método de seleção que consiste em escolher o melhor indivíduo da população atual para transmitir seus genes aos demais indivíduos da população por meio do operador genético *crossover* (ou cruzamento), formando a nova geração de cromossomos, ou indivíduos. Há autores que recomendam escolher uma porcentagem de indivíduos que irão receber parte dos genes do melhor cromossomo.
- **Cruzamento ou *Crossover*:** Este operador proporciona troca de informação genética entre indivíduos e, sendo assim, representa um importante mecanismo na geração de novas possíveis soluções no espaço de busca. O *crossover* produz um novo indivíduo a partir de outros dois indivíduos selecionados da população. A utilização do *crossover*, juntamente com o elitismo, visa garantir que as características dos melhores indivíduos sejam transmitidas para gerações futuras.
- **Predação:** Assim como a mutação, esse operador genético insere diversidade genética na população e tem, como meta principal, fazer com as soluções saiam de um ótimo local e possam convergir para um ótimo global. A predação elimina os indivíduos menos adaptados ao repor os indivíduos descartados por novos indivíduos gerados aleatoriamente. Lembrando que essa alteração não garante que o indivíduo que substituirá o indivíduo predado seja melhor. Essa operação de predação acontece num período determinado, como por exemplo, a cada geração ou após um número pré-determinado de gerações.
- **Mutação:** A mutação é responsável por inserir material genético novo, substituindo algumas partes dos cromossomos por novos valores escolhidos aleatoriamente, visando garantir que as gerações seguintes continuem evoluindo e, ainda, restaurar genes perdidos durante o cruzamento ou até mesmo na própria mutação. Uma taxa de mutação pequena conduz o algoritmo a ficar estagnado, com soluções próximas de um ótimo local. Um alto valor da taxa de mutação conduz o algoritmo a uma busca aleatória. Os efeitos das mutações chamadas benéficas, que melhoram a solução, persistem ao longo das gerações, enquanto que os efeitos das mutações ruins tendem a desaparecer.

Conforme Soares (1997), a escolha ideal dos valores dos parâmetros do algoritmo é um problema não linear e dependente do tipo de problema tratado. Isso dificulta que se encontre uma boa configuração para generalizar a execução de qualquer tipo de problema. Normalmente, os valores dos parâmetros são pré-fixados. No entanto, por ser um processo dinâmico que apresenta evolução no tempo e no espaço das possíveis soluções, a predefinição geral de um conjunto de parâmetros satisfatórios é bem difícil (Linden, 2008). É importante salientar que os efeitos decorrentes da escolha inadequada desses parâmetros vão desde aumento no tempo de convergência, convergência prematura, estagnação da busca, maior necessidade de recursos computacionais até a não-convergência para uma solução viável, tornando a escolha pelo uso desse método de otimização inconveniente.

4. MÉTODO DE ANÁLISE

A estrutura do método de análise desenvolvido neste estudo divide-se em três grandes fases, conforme mostrado na Figura 1: Pré-Calibração, Calibração e Validação da rede microssimulada. O método é propositalmente apresentado de forma geral com o intuito de poder ser aplicado a outros estudos de desenvolvimento de redes microssimuladas. Os

detalhes de cada passo do método aplicado neste estudo serão apresentados e discutidos no estudo de caso (seção 5).

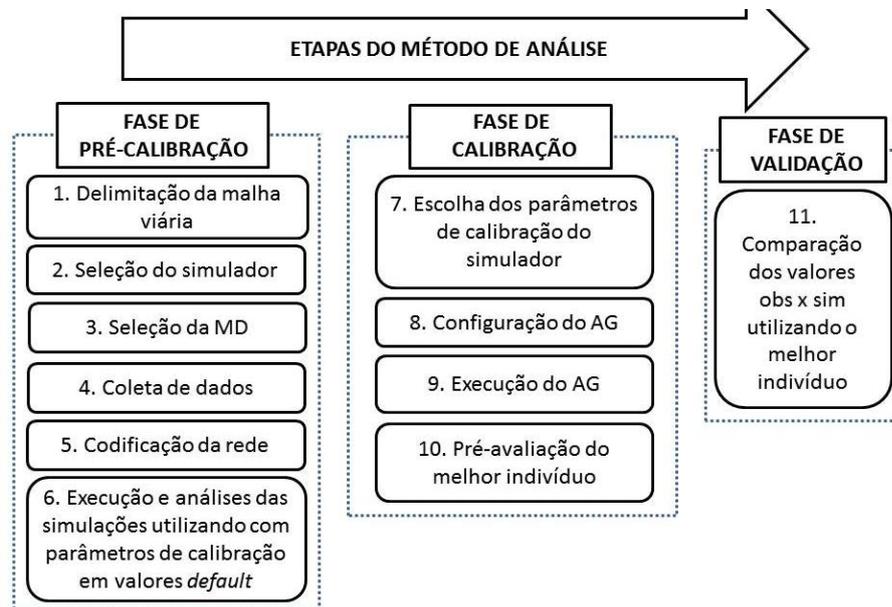


Figura 1: Etapas do método de análise.

Na primeira etapa, denominada Fase de Pré-Calibração, delimita-se a malha viária a ser simulada, define-se o microssimulador, bem como as medidas de desempenho que serão utilizadas. Os dados a serem coletados são as medidas de desempenho e os dados de entrada do simulador, que incluem os parâmetros do modelo que serão diretamente informados pelo usuário. Em seguida, realiza-se a codificação da rede, e por fim, realizam-se as simulações e as análises utilizando os valores *default* dos parâmetros de calibração do microssimulador. Vale ressaltar que os resultados podem sugerir que mais algum parâmetro seja coletado em campo. Desta forma a rede é avaliada novamente com os novos dados de entrada, e a fase de Pré-Calibração é finalizada quando se considera que a Fase de Calibração pode reduzir o erro a valores desejáveis.

Na segunda etapa, chamada Fase de Calibração, realiza-se a calibração propriamente dita. Com base na análise das simulações da etapa anterior, decide-se quais parâmetros serão calibrados e quais permanecerão com seus valores *default*. São definidos também os intervalos de busca dos valores aceitáveis dos parâmetros. Em seguida é definida a configuração do AG, que consiste na escolha dos valores de seus parâmetros e operadores genéticos. Passa-se a execução do AG, e o melhor conjunto de parâmetros (indivíduo) passa por uma avaliação conceitual, na qual o valor de cada parâmetro calibrado é analisado qualitativamente com o objetivo de se verificar se os valores são condizentes com o fenômeno em análise.

Na terceira e última etapa, a Fase de Validação, realizam-se comparações entre os valores simulados e observados valendo-se de ferramental de inferência estatística, mais especificamente análise de correlação e estimação intervalar da média das diferenças entre os valores simulados e observados. O principal objetivo desta fase é avaliar a capacidade do modelo de representar o fenômeno utilizando um novo conjunto de dados.

5. ESTUDO DE CASO

5.1. Fase da Pré-Calibração

A malha viária selecionada, situada numa das regiões mais adensadas da cidade de Fortaleza, foi a mesma utilizada por Maia (2007). A região é reticulada e compreende 4 x 2 quarteirões cobrindo uma área de dimensões 600 m x 400 m, onde se encontram prédios residenciais e estabelecimentos comerciais com intensa atividade, o que resulta em velocidades nos principais corredores de aproximadamente 10 km/h na hora de pico. A malha é composta por nove vias, sendo três na direção leste-oeste, e seis na direção norte-sul. Há 15 interseções em nível, das quais 8 são controladas por semáforos operados pelo sistema adaptativo SCOOT – *Split Cycle Offset Optimization Technique*, sob a gerência do CTAFOR – Controle de Tráfego Avançado de Fortaleza.

O microssimulador escolhido para o estudo foi o VISSIM versão 5.30 (PTV, 2010), cujos algoritmos de *car-following*, mudança de faixa e aceitação de brechas simulam o comportamento das unidades individuais veículos/condutores com um bom equilíbrio entre complexidade e grau de representatividade. O modelo de *car-following* Wiedemann-99 baseia-se no famoso modelo psico-físico proposto por Wiedemann e Reiter (1992). O VISSIM modela as principais medidas de desempenho do tráfego em diferentes níveis de agregação espacial e temporal, além de oferecer uma interface com o usuário bastante amigável.

Para a fase de calibração, a medida de desempenho do tráfego escolhida foi o tempo de viagem médio agregado por via. Cada um dos nove valores de tempo de viagem médio foi comparado com o valor do indicador observado em campo, resultando em nove valores de erro percentual absoluto (EPA). A medida de ajuste utilizada na calibração foi a média aritmética dos nove valores de EPA, ou seja, o erro percentual absoluto médio (EPAM). Para a fase de validação, optou-se por ter a medida de desempenho tempo de viagem médio desagregada por arco e por intervalos de 15 minutos. Além desta medida de desempenho, na validação avaliou-se também a capacidade do modelo em estimar a variável fluxo (veíc/h), também desagregada por arco e por períodos de 15 minutos.

Além das medidas de desempenho, outras informações são necessárias para a codificação da rede. Estas informações são denominadas *dados de entrada*. Basicamente, os dados de entrada para um projeto de microssimulação consistem nas informações de demanda e de infraestrutura viária, e dos parâmetros do modelo cujos valores são informados pelo usuário. Neste estudo, decidiu-se coletar dados de dois parâmetros do modelo do VISSIM na rede em estudo: a *brecha crítica*, e a *velocidade máxima desejada*. O primeiro representa brecha mínima (em segundos) aceita pelos veículos em aproximações secundárias de interseções não semaforizadas. Já o segundo, como sugere a terminologia, representa a velocidade que os veículos atingirão quando não houver veículos à frente. A decisão de se coletar estas informações deve-se à relativa facilidade de observação em campo, bem como a relevância destes parâmetros na modelagem do comportamento do tráfego em redes urbanas. Além disto, a diminuição de dois parâmetros a serem calibrados pode aumentar consideravelmente a qualidade da fase de calibração, pois não só há redução na dimensionalidade do problema de otimização, como também valores bem estimados em campo dos dois parâmetros (dados de entrada) tendem a reduzir o espaço de busca dos parâmetros de calibração, devido à relação de dependência existente entre os parâmetros.

O método da coleta dos dados em campo é detalhada por Maia (2007). A coleta resultou em uma matriz-OD com 42 zonas e aproximadamente 10 mil viagens no período de hora analisado. As informações de transporte público, obtidas juntamente à Empresa de Transportes urbanos de Fortaleza, foram os itinerários, os pontos de parada e os *headways* das 17 linhas de ônibus que passam pela rede. A *brecha crítica* observada foi de 4,5 segundos, e a *velocidade máxima desejada* foi de 40 km/h, valor este inclusive utilizado pelo CTAFOR no dimensionamento das progressões semaforicas de tempo fixo por banda de passagem em período de baixa demanda. Os dados das variáveis de saída utilizadas na validação (tempo de viagem médio e fluxo nos arcos internos da rede em períodos de 15 minutos) e os dados de programação semaforica foram obtidos pelo banco de dados do sistema SCOOT.

Depois da coleta e consolidação dos dados, a rede foi codificada. Antes de simulá-la com os parâmetros em *default*, foi executado o modelo de alocação de tráfego do VISSIM. A alocação é feita de forma iterativa, ou seja, os usuários escolhem suas rotas baseado nos custos de viagem experienciados nas iterações anteriores. O manual do software chama o modelo de alocação *Dynamic Assigment*, mas trata-se na realidade de uma alocação do tipo equilíbrio estocástico do usuário (Fellendorf e Vortisch, 2010). O critério de parada para a convergência foi a diferença dos tempos de viagem entre os pares OD de iterações subsequentes ser menor do que 15%, que aconteceu em apenas 6 iterações. Ainda nesta etapa de alocação foi realizada uma verificação das três melhores rotas escolhidas pelo modelo entre os principais pares OD; observou-se que estas estavam condizentes com as rotas observadas em campo.

Neste primeiro momento de verificação da rede optou-se por manter todos os parâmetros do simulador com seus valores default, inclusive o de *brecha crítica* (3,0 s) e *velocidade máxima desejada* (60 km/h), como também não incluir o transporte público. A simulação resultou num EAPM médio de 29%. Ao se avaliar o erro de cada via individualmente, percebeu-se que os tempos de viagem simulados eram menores que os valores de campo, em particular nas vias secundárias. Esta maior fluidez da rede simulada pode ser explicada pela menor impedância causada pela ausência do transporte público e pelos valores *default* de brecha crítica e de velocidade média desejada serem menores do que os valores observados em campo.

Em seguida, foram inseridos na simulação o transporte público e os valores coletados de *brecha crítica* e de *velocidade máxima desejada*. Após estas alterações, foram realizadas 30 replicações que resultaram num EPAM com média de 13%, e desvio padrão de 1%. Embora um EPAM de 13% seja relativamente baixo, partiu-se para a calibração com o objetivo de se avaliar a contribuição trazida por esta fase.

5.2. Fase de Calibração

A seleção dos parâmetros do VISSIM a serem calibrados baseou-se trabalhos encontrados na literatura (Cunto e Saccomanno, 2008; Menneni *et al.*, 2008, Oliveira e Cybis, 2008). Foram calibrados os seguintes parâmetros do modelo *car-following* Wiedemann-99: *Standstill Distance* (CC0), *Headway Time* (CC1), *Following Variation* (CC2), *Threshold for Entering Following* (CC3), *Negative Following Threshold* (CC4), *Positive Following Threshold* (CC5) e *Speed Dependency of Oscillation* (CC6). Foram calibrados também os seguintes parâmetros do modelo de mudança de faixa: *Min. Headway* (MH), *Safety Distance Reduction Factor* (SD) e *Max. Deceleration For Cooperative Braking* (MD).

A próxima etapa da fase de calibração é a escolha da configuração do AG, ou seja, a escolha dos valores dos seus parâmetros e seus operadores genéticos. Inicialmente buscou-se definir o número de replicações por indivíduo. Os resultados das 30 replicações feitas com os parâmetros em valores *default* indicaram um desvio padrão do EPAM de apenas 1%, com o valor mínimo 10,0% e valor máximo 14,8%. A baixa dispersão dos valores de MAPE levou a se optar por utilizar somente uma replicação por indivíduo no processo de calibração. Isto contribuiu significativamente para a redução do tempo gasto na calibração.

Para a escolha dos valores dos parâmetros do AG foram conduzidos experimentos para se avaliar o efeito de alguns parâmetros no erro de calibração. Inicialmente foram testados quatro cenários, variando-se tamanho da população em dois níveis (10 e 30 indivíduos) e a diversidade também em dois níveis (1 e 2). Os outros parâmetros foram mantidos constantes: número máximo de gerações (30), taxa de mutação (30%) e taxa de predação (20%). Os resultados da Figura 2 mostram que o AG se mostrou razoavelmente melhor com um maior número de indivíduos. Percebeu-se também que inserindo diversidade a cada duas gerações foi possível atingir um erro menor comparado aos erros gerados nos outros cenários. Esse resultado corrobora com a orientação de que os operadores genéticos sejam aplicados em gerações não subsequentes para que o efeito destes sejam assimilados pela população.

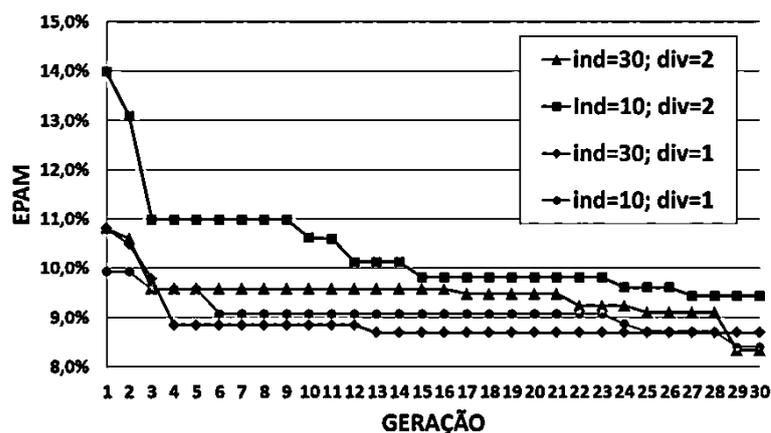


Figura 2: Variação do número de indivíduos e diversidade.

Continuando a busca pelo conjunto de valores dos parâmetros do AG, fixou-se a diversidade em 2 e variou-se as taxa de mutação (10% e 30%) e, novamente, o número de indivíduos (10 e 30) e os demais parâmetros foram mantidos constantes. Resolveu-se testar novamente o número de indivíduos com os novos valores de predação porque um número mais baixo de indivíduos reduziria em um terço o esforço computacional despendido na calibração. De acordo com a Figura 3, a melhor convergência se deu utilizando o maior número de indivíduos e a menor taxa de mutação. Um baixo valor da taxa de mutação previne uma convergência prematura, porém prejudica a busca por uma solução ótima global, pois reduz a capacidade do algoritmo explorar o intervalo de busca. Porém, o valor da taxa de mutação fixado em 10% garantiu uma melhor solução para o problema em questão. Em resumo, os valores dos parâmetros do AG que resultaram no melhor desempenho, ainda que marginal, foram: número de indivíduos=30; número de gerações=30; diversidade=2; taxa de

mutação=10% e taxa de predação=20%. Com esta configuração o algoritmo convergiu para um valor de erro de aproximadamente 8% em apenas cinco gerações (Figura 3).

É importante notar que em todas as oito configurações analisadas, o algoritmo convergiu a partir da 12ª geração para valores de erro similares aos da 30ª geração, os quais ficaram entre 8,1% e 9,5%, valores considerados próximos.

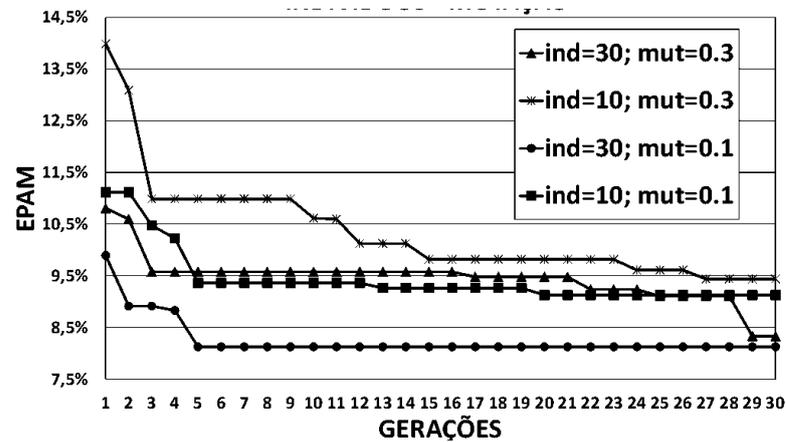


Figura 3: Variação do número de indivíduos e taxa de mutação.

O último passo antes de iniciar a etapa de validação é uma pré-avaliação do melhor indivíduo, que consiste numa avaliação qualitativa do valor calibrado de cada parâmetro. A tabela 1 mostra os valores calibrados e os valores *default* dos 10 parâmetros de calibração da rede. Percebe-se que os parâmetros CC4, CC5, CC6 e MD apresentaram as maiores diferenças entre os valores calibrados e *default*.

Tabela 1: Valores default e otimizados dos parâmetros.

	PARÂMETROS									
	CC0	CC1	CC2	CC3	CC4	CC5	CC6	MH	SD	MD
Default	1,5	0,9	4,0	-8,0	-0,4	0,4	11,4	0,5	0,6	-3,0
Otimizado	0,5	0,2	1,5	-15,0	-2,0	2,0	2,1	0,5	0,2	-9,0

Os parâmetros CC4 e CC5, dois dos parâmetros mais calibrados na literatura (Oliveira e Cybis, 2008), exercem grande importância no comportamento dos veículos em regime de *following*, pois representam os limites de diferenças entre as velocidades acima dos quais o veículo seguidor reagirá para se manter no processo de *following*. Portanto, quanto maior forem os valores de CC4 e CC5, menor será a sensibilidade do veículo seguidor à diferença absoluta de velocidade para o veículo líder, o que ocorre para o tráfego de velocidades mais baixas, típico de ambiente urbano. O parâmetro CC6 mede a influência da distância entre os veículos na oscilação da velocidade do veículo seguidor quando no processo de *following*; quanto menor for o valor de CC6, menor a oscilação da velocidade com o aumento da distância. O parâmetro MD representa a máxima desaceleração (em m/s^2) de um veículo ao cooperar com a mudança de faixa de um veículo na faixa adjacente. O valor calibrado indica que os veículos da rede são mais capazes de desacelerar do que o veículo *default*, o que é esperado em ambiente urbano, onde as velocidades são menores.

O número de replicações por indivíduo utilizado reduziu substancialmente o tempo total de calibração. Na calibração do AG selecionado, 900 indivíduos foram testados, cada um com tempo de execução de aproximadamente 30 segundos, o que resultou num tempo de 7,5 horas. Caso o número de replicações por indivíduo fosse igual a 5, valor este comumente encontrado na literatura, a fase de calibração passaria a durar 37,5 horas.

5.3. Fase de Validação

A etapa de validação foi baseada no procedimento proposto por Maia (2007), que realizou um esforço de calibração e validação de um meso e um microsimulador de tráfego na mesma malha viária utilizada nessa pesquisa. A medida de desempenho do tráfego utilizada foi o tempo de viagem médio (s/veículo) em 13 arcos internos da rede em períodos de 15 minutos, além do fluxo veicular também com mesmo nível de agregação. Assim, a medida de desempenho é mais desagregada espacialmente e temporalmente na fase de calibração, o que é desejável, uma vez que na análise de validação a comparação dos valores observados e simulados deve ser mais rigorosa do que na fase de calibração. Além disso, a estimação destas variáveis desagregadas exige do modelo maior capacidade de representação do comportamento do tráfego na rede.

As observações das medidas de desempenho para validação foram obtidas no banco de dados do sistema SCOOT, coletados no período do pico da tarde de dias típicos dos meses de abril, maio e junho de 2006. Vale ressaltar que estes provêm de estimações feitas pelo sistema SCOOT a partir de ocupação veicular sobre o laço, e não de observações diretas em campo. Foram realizadas comparações dos valores fornecidos pelo SCOOT e os coletados em campo de fluxo veicular em períodos de 15 minutos em seis aproximações. Foram construídos intervalos com grau de confiança de 95% para a média das diferenças em cada uma das seis aproximações. O resultado mais desfavorável à estimação do SCOOT foi o intervalo [-20; 50] veículos por hora, e um EPAM de 8%. A mesma análise foi conduzida para a variável atraso veicular médio, que está diretamente relacionada com o tempo de viagem médio no link. O intervalo de confiança mais desfavorável foi [-5;1] segundos por veículo, com um EPAM de 10%.

A Figura 4 mostra gráfico de dispersão para auxiliar a comparação entre os dados simulados e os dados observados. Na comparação da variável tempo de viagem médio, o coeficiente de correlação amostral encontrado foi de $r = 88\%$ e um EPAM de 13%. Para a variável fluxo, foram obtidos um coeficiente de correlação amostral $r = 74\%$ e um EPAM de 18%. Os intervalos de confiança (95%) para a média das diferenças foram e [0; 2] s/veículo e [-105; 210] veículos/h para o tempo de viagem médio e o fluxo, respectivamente.

Os resultados indicam que a rede de microsimulação modelou satisfatoriamente os tempos de viagem médio nos arcos. Para a variável fluxo, percebe-se que há uma tendência a superestimação à medida que o fluxo aumenta. Uma possível causa para isto é a limitação do sistema SCOOT na estimação desta variável para períodos de congestionamento, pois o sistema perde qualidade de estimação quando a fila de veículos se estende para além do laço detector.

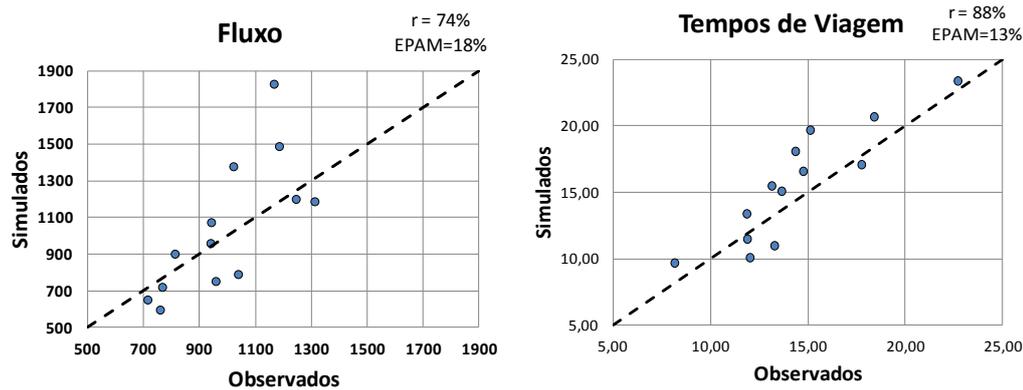


Figura 4: Comparação do fluxo (veíc/h) e tempo de viagem médio (seg/veic) simuladas e observadas.

6. CONCLUSÕES

A variabilidade do erro percentual absoluto médio (EPAM) foi baixa para a rede em estudo, o que significa que o ganho em se replicar mais de uma vez cada simulação não justificaria o tempo despendido. Recomenda-se, porém, que uma análise da variabilidade da medida de desempenho ou de erro seja conduzida antes da escolha do número de replicações.

A redução do erro causada pela inserção da informação do valor de dois parâmetros do modelo e pela inserção do transporte público foi superior à redução do erro trazida pela fase de calibração. A inclusão dos valores de *brecha crítica*, *velocidade máxima desejada* e das linhas de ônibus à rede reduziu o EPAM de 29% para 13% enquanto a calibração com a melhor configuração de AG reduziu o erro de 13% para 8%. Isto significa que a fase de codificação é crucial para o bom desempenho do modelo de simulação, o que contrasta com o desequilíbrio de atenção dada em favor da calibração de parâmetros comportamentais na literatura. Além disto, se os dois parâmetros tivessem sido calibrados ao invés de coletados em campo, a otimização poderia resultar em valores calibrados que não representassem bem os valores reais, mesmo que o EPAM de calibração resultante chegasse a valores tão baixos quanto 8%.

O efeito dos valores dos parâmetros e operadores genéticos do AG no processo de calibração foi pequeno, tanto no que diz respeito à velocidade de convergência quanto ao valor final do erro. Portanto, para redes de tráfego como a tratada neste trabalho, a escolha da configuração do AG pode ser embasada na literatura, sem a necessidade de se avaliar o melhor conjunto de parâmetros por meio de experimentos como os conduzidos aqui.

Por fim, a classificação dos parâmetros do microssimulador em *dados de entrada* e *parâmetros de calibração* facilitou bastante a comunicação e a compreensão da equipe na execução deste trabalho.

REFERÊNCIAS BIBLIOGRÁFICAS

- Ayala, R. J. (2013) *Procedimento para Identificação dos Principais Parâmetros dos Microssimuladores a serem Considerados no Processo de Calibração*. Dissertação de Mestrado. Universidade de Brasília.
- Barceló, J. E. (2010) *Fundamentals of Traffic Simulation*. International Series in Operations Research and Management Science, Springer.

- Bessa Jr., J. E.; Lima, F. A. A.; Cunha, A. L. B. N. e Setti, J. R. (2008) Calibração do Modelo de Desempenho do Simulador INTEGRATION Através de um Algoritmo Genético. Congresso Anual da ANPET.
- Bessa Jr., J. E., e Setti, J. R. (2012) Relações Fluxo-Velocidade para Rodovias de Pista Simples no Brasil. *Anais do XXVI Congresso de Pesquisa e Ensino em Transportes*, ANPET, Joinville-SC, CD-ROM.
- Cunto, F. e Saccomanno, F.F. (2008) Calibration and Validation of Simulated Vehicle Safety Performance at Signalized Intersections. *Accident Analysis and Prevention*, n. 40, pp. 1171-1179
- Egami, C. Y.; Setti, J. R. e Rilett, L. R. (2004) Algoritmo Genético Para Calibração Automática De Um Modelo De Simulação De Tráfego Em Rodovias De Pista Simples. *Transportes* (Rio de Janeiro), v. 12, p. 5-14.
- Fellendorf, M. e Vortisch, P. (2010). *Traffic Simulation with VISSIM. Fundamentals of Traffic Simulation*. International Series in Operations Research and Management Science, Cap. 2, Ed. Springer.
- Hellinga, B. R. (1998) Requirements for The Calibration of Traffic Simulation Models. Proceedings of the Canadian Society for Civil Engineering, v.1, p. 211-222.
- Hollander, Y. e R. Liu (2008) The Principles of Calibrating Traffic Microsimulation Models. *Transportation*, v. 35, p. 347-362.
- Hourdakis, J.; P. G. Michalopoulos e J. Kottommannil (2003) Practical Procedure for Calibrating Microscopic Traffic Simulation Models. *Transportation Research Record*, n. 1852, p. 130-139.
- Kim, K. e L. R. Rilett (2001) Genetic Algorithm Based Approach for Calibration Microscopic Simulation Models. IEEE Intel. Transp. Systems Conference Proceedings, Oakland, CA, USA, p. 698-704.
- Linden, R. (2008) *Algoritmos Genéticos: Uma importante ferramenta da Inteligência Computacional*. 2ª Ed. Editora Brasport. Rio de Janeiro, Brasil.
- Ma, J.; H. Dong e H. M. Zhang (2007) Calibration of Microsimulation with Heuristic Optimization Methods. *Transportation Research Record 1999*, TRB, National Research Council, Washington, D.C., p. 208-217.
- Ma, T. e B. Abdulhai (2002) Genetic Algorithm-based Optimization Approach and Generic Tool for Calibration Traffic Microscopic Simulation Parameters. *Transportation Research Record 1800*, p. 6-15.
- Maia, F. V. B. (2007) *Calibração e Validação de Modelos de Meso e Microsimulação do Tráfego para a Avaliação de Intervenções Tático-Operacionais na Malha Viária Urbana*. Dissertação de Mestrado, Programa de Mestrado em Engenharia de Transportes, Universidade Federal do Ceará, Fortaleza, CE.
- Menneni, S.; Sun, C. e Vortisch, P. (2008) Microsimulation Calibration Using Speed-Flow Relationships. *Transportation Research Record*, n. 2088, p. 1-9.
- Mon-Ma, M. L. (2008) *Adaptação do HCM-2000 para rodovias de pista simples com faixas adicionais típicas do Estado de São Paulo*. 162p. Tese (Doutorado) EESC-USP, São Carlos.
- Oliveira, M. L. e Cybis, H. B. (2008) Revisão da Experiência de Calibração do Software Vissim Aplicado a um Estudo de Caso de Autoestrada Brasileira. VIII SEPROSUL – Bento Gonçalves, Brasil.
- Pacheco, M. A. C. (1999) Algoritmos Genéticos: Princípios e Aplicações. Laboratório de Inteligência Computacional Aplicada. Pontifícia Universidade Católica do Rio de Janeiro.
- Park, B. B. e H. Qi (2005) Development and Evaluation of a Procedure for the Calibration of Simulation Models. *Transportation Research Record*, n.1934, p. 208-217.
- PTV (2010) VISSIM 5.30. User Manual. Planung Transport Verkehr AG, Karlsruhe, Germany, 2010.
- Soares, G. L. (1997) Algoritmos Genéticos: Estudo, Novas Técnicas e Aplicações. Programa de Pós-Graduação em Engenharia Elétrica, UFMG, Belo Horizonte.
- Song, G. L.; Yu, L. e Zhang, Y. (2012) Applicability of Traffic Microsimulation Models in Vehicle Emissions Estimates. Case Study of VISSIM. *Transportation Research Record 2270*, pp. 132-141.
- Toledo, T. e Koutsopoulos, H. N. (2004) Statistical Validation of Traffic Simulation Models. *Transportation Research Record*, no. 1876, pp. 142-150.
- Wiedemann, R. e Reiter, U. (1992) Microscopic Traffic Simulation - The Simulation System Mission – Background and Actual State.
- Zhang, Z.; Spansel, K. e Wolshon, B. (2013) Megaregion Network Simulation for Evacuation Analysis. Encontro Anual do Transportation Research Board, Artigo No. 13-4317, TRB.

André Luis Medeiros (andremed@det.ufc.br).

Manoel Mendonça de Castro Neto (manoel@det.ufc.br)

Carlos Felipe Grangeiro Loureiro (felipe@det.ufc.br)

Departamento de Engenharia de Transportes, Universidade Federal do Ceará. Campus do PICI, s/n – Bloco 703 – CEP. 60455-760 – Fortaleza, CE, Brasil.

José Elievam Bessa Júnior (elievamjr@gmail.com)

Departamento de Engenharia de Transportes, Escola de Engenharia de São Carlos, Universidade de São Paulo.

Av. Dr. Carlos Botelho, 1465 – São Carlos, SP, Brasil