

## Designação de Veículos Autônomos em Abordagens Mono-objetivo e Multiobjetivo

Catrine dos Santos Oliveira<sup>1</sup>, Marconi de Arruda Perreira<sup>1</sup>

<sup>1</sup>Departamento de Tecnologia e Eng. Civil, Computação e Humanidades  
Universidade Federal de São João Del Rei - Campus Alto Paraopeba MG 443, KM 7  
Ouro Branco – MG – Brasil

catrine.sntsoliveira@gmail.com, marconi@ufsj.edu.br

**Abstract.** *This work proposes alternatives to optimize the designation of autonomous vehicles according to the distance traveled by the automobile to the requester and the time that this client waits for this vehicle to arrive to answer the call. This paper is the continuation of another work, whose exclusive focus was to minimize the distance that vehicles must travel to serve the customer. The tool proposed here presents improvements both in execution time and in a more complete analysis: the optimization model used has become multiobjective, minimizing both the service time and the distance to be covered. The results show 90% of gain in execution time and 15% in service time when compared to the previous version.*

**Resumo.** *Este trabalho propõe alternativas para otimização da designação de veículos autônomos, em termos da distância percorrida pelo veículo até o solicitante e o tempo que este cliente espera para que o veículo chegue para atender ao chamado. O estudo em questão é a continuidade de outro trabalho, o qual focava exclusivamente na minimização da distância que os veículos devem percorrer para atender o cliente. A ferramenta proposta nesse artigo apresenta melhorias tanto no tempo de execução quanto uma análise mais completa: o modelo de otimização usado agora é multiobjetivo, minimizando tanto o tempo de atendimento quanto a distância a ser percorrida. Os resultados apresentam um ganho da ordem de 90% no tempo de execução e em 15% no tempo de atendimento, em relação à versão anterior.*

### 1. Introdução

O cenário atual de transporte urbano conta com novas formas de mobilidade, plataformas que conectam veículos diretamente aos passageiros, tais como Uber, 99Taxi e Cabify, os quais oferecem uma forma de utilização de veículos sob demanda. Segundo [Fonseca, 2020] a expectativa é que até 2030, carros autônomos de diferentes níveis se tornem um grande mercado mundial movimentando um capital em torno de US\$ 60 bilhões. Desse modo, tanto na conjuntura vigente quanto no futuro próximo, o problema de alocação de veículos mostra-se relevante.

O problema de alocação consiste na atribuição de veículos a um conjunto predeterminado de viagens (passageiros), tendo em vista a minimização dos custos operacionais. Logo, uma alocação otimizada visando a redução do tempo de atendimento ao cliente e a redução da distância percorrida pelo veículo implica em

menos gastos, conseqüentemente o serviço pode ser oferecido a preços mais acessíveis. Percebe-se assim que o problema possui uma natureza multiobjetivo.

[Alcântara & Pereira, 2019] apresentaram um estudo para o problema de alocação de veículos por meio da abordagem mono-objetivo, com intuito de minimizar a distância total percorrida pelos veículos. A abordagem proposta foi comparada a dois outros algoritmos: o primeiro reunia as chamadas recebidas durante uma janela de 50 segundos e executava o Algoritmo Húngaro [Kuhn, 1955] para alocação dos veículos para cada chamada; o segundo é baseado numa estratégia gulosa, na qual, para cada chamada realizada, aloca-se o veículo que necessita percorrer a menor distância para atender à requisição. Como o modelo baseado no algoritmo Húngaro resulta numa resposta eficiente, porém demanda muito tempo de processamento e o modelo baseado na estratégia gulosa gera uma resposta pior que a anterior, apesar de gerar o resultado rapidamente, o trabalho de [Alcântara & Pereira, 2019] focou na proposta de um algoritmo que gerasse uma resposta que tentasse ser o mais próxima o possível da obtida pelo modelo Húngaro, porém gerada num menor tempo, tentando ser tão rápida quanto a obtida pela estratégia gulosa.

O presente artigo propõe melhorias no trabalho supracitado. Inicialmente, o foco voltou-se para a elaboração de versões aperfeiçoadas do algoritmo genético para reduzir o tempo de execução sem perder na qualidade da resposta. Posteriormente, o modelo se tornou multiobjetivo, minimizando tanto o tempo de atendimento quanto a distância a ser percorrida.

## **2. Algoritmo Genético Mono-objetivo**

O Algoritmo Genético proposto em [Alcântara & Pereira, 2019] ainda apresentava um tempo de processamento muito maior que o demandado pelo modelo guloso. Assim, o presente estudo propõe estratégias para reduzir o tempo de resposta do Algoritmo Genético, com a finalidade de aproximar-se do tempo de execução do Algoritmo Guloso, sem perdas na minimização da distância. Nessa fase, manteve-se as configurações do cenário de simulações utilizadas no trabalho anterior, de forma a garantir que as comparações entre os trabalhos sejam válidas.

Uma forma de diminuir o tempo de execução de um algoritmo genético é reduzindo a quantidade de gerações criadas. Usar um número fixo de gerações a serem produzidas pode fazer com que o algoritmo gere novas soluções que não estão mais apresentando melhorias em relação às respostas anteriores. Esse era o caso do trabalho anterior, onde o algoritmo sempre gerava um número fixo de gerações igual a 200.

Com o intuito de interromper a produção de gerações quando não se observava mais melhorias significativas nas soluções geradas, ou seja, nos casos em que a variabilidade das novas gerações é baixa. Elaborou-se três novas versões (Gen-I, Gen-II Gen-III), que apresentam diferentes formas de verificação da evolução da população de soluções geradas. Cada versão possui seus próprios critérios de parada, que, quando alcançados, geram a interrupção da produção de novas gerações. Em todas as versões foi utilizado um tamanho de população igual a 1.000 indivíduos. Os demais parâmetros são os mesmos usados em [Alcântara & Pereira, 2019].

As versões Gen-I e Gen-II buscam verificar se a variabilidade das gerações que estão sendo produzidas continua existindo, parando de produzir novas quando considera

que a variabilidade está baixa. A Gen-III é uma combinação das anteriores, motivada pelos bons resultados gerados pelas referidas versões.

A Gen-I analisa se ocorre evolução entre as gerações e nos indivíduos de cada geração. Os critérios são: (1) os 10 melhores indivíduos da geração corrente (1% da população) são iguais entre si; e (2) os melhores indivíduos da geração corrente são iguais aos melhores indivíduos das 10 últimas gerações.

A Gen-II analisa se ocorre evolução somente entre as gerações. O critério é: os melhores indivíduos da geração atual são iguais aos melhores indivíduos das 10 últimas gerações. Aqui foram geradas 2 subversões: a subversão (A) considera os melhores 3% indivíduos da população; a subversão (B) considera 1% dos melhores indivíduos da população.

A Gen-III consiste na junção das versões Gen-I e Gen-II, onde nas 99 primeiras gerações são utilizados os critérios da Gen – I; a partir da geração 100 utiliza-se o critério da Gen – IIB.

### 3. Algoritmo Genético Multiobjetivo

A abordagem multiobjetivo de um problema de otimização possibilita a obtenção de um conjunto soluções que satisfaça as restrições do problema e aperfeiçoe um vetor de funções objetivo [Gaspar-Cunha, Takashi, & Antunes, 2013]. É muito popular nesse contexto o uso de Algoritmos Evolutivos, pois estes são capazes de evoluir simultaneamente todo um conjunto de diferentes indivíduos, onde cada um deles corresponde a uma possível solução para o problema.

O problema de alocação de veículos pode ser tratado como um problema multiobjetivo visando: (1) minimizar a distância média percorrida pelos veículos para realizar o atendimento, (2) minimizar a distância total percorrida pelos veículos, (3) minimizar o tempo total para atendimento e (4) minimizar o tempo médio para atendimento. Logo, o estudo do tempo de atendimento faz-se necessário, pois embora seja natural pensar que o tempo de atendimento é proporcional à distância percorrida, particularidades no trânsito de cada trajeto impedem que o pressuposto descrito seja sempre verdadeiro.

#### 3.1. Modelagem Matemática

Matematicamente optou-se pela interpretação do problema da minimização da distância como a minimização da função:

$$z_1 = \sum_{i=1}^m \sum_{j=1}^n g_{ij} * d_{ij} \quad (1)$$

Onde  $n$  representa o número de solicitações de veículo, ou seja, o número de linhas em cada uma das matrizes de dados;  $m$  representa a quantidade de veículos que podem realizar viagens, isto é, o número de colunas em cada uma das matrizes de dados. A variável  $g_{ij}$  é binária e sinaliza se o veículo  $i$  aceitou ou não a solicitação de viagem  $j$ . Assim,  $g_{ij} = 1$ , se a viagem tiver sido aceita e  $g_{ij} = 0$ , se a viagem não tiver sido aceita. A variável  $d_{ij}$  é o valor armazenado na posição  $ij$  da matriz  $D$  com os valores de distância da viagem do veículo  $i$  para a solicitação  $j$ .

A minimização do tempo de atendimento consiste na minimização da função:

$$z_2 = \sum_{i=1}^m \sum_{j=1}^n g_{ij} * t_{ij} \quad (2)$$

Onde a variável  $t_{ij}$  é o valor armazenado na posição  $ij$  da matriz  $\mathbf{T}$  com os valores de tempo da viagem do veículo  $i$  para a solicitação  $j$ .

O problema multiobjetivo é resultado da minimização da função:

$$z_3 = \sum_{i=1}^m \sum_{j=1}^n g_{ij} * (d_{ij} + t_{ij}) \quad (3)$$

#### 4. Simulações e Parametrização

O software utilizado para simulação do tráfego é o *Simulation of Urban MObility* (SUMO<sup>1</sup>), o qual possibilita simular um veículo percorrendo uma via, configuração de uma malha viária, entre outros recursos. Neste trabalho conservou-se o mapa proposto em [Alcântara & Pereira, 2019]. Os parâmetros utilizados são: 850 veículos autônomos para atender às solicitações, 18.000 veículos pessoais: carros e motocicletas, que transitam em 50.000 rotas distintas. Os algoritmos foram executados em um ASUS Z450U Intel<sup>®</sup> Core<sup>™</sup> i5-7200U e 8 GB de RAM. Foram criados dois cenários distintos de simulação, os quais serão descritos a seguir.

##### 4.1. Simulação 1

Aqui, a simulação é configurada de forma semelhante à descrita em [Oliveira et al. 2015]. Ela foi utilizada para testar os algoritmos mono-objetivo. Seus detalhes:

- Os veículos, autônomos e pessoais, são distribuídos aleatoriamente no mapa. Durante todo o tempo de simulação, os veículos pessoais podem entrar e sair da rede, simulando o fluxo de tráfego;
- Quando um veículo autônomo se torna ocupado, um ocupado torna-se livre, mantendo assim a proporção de veículos autônomos livres e ocupados. No decorrer da simulação sempre haverá metade dos veículos desocupados e a outra metade ocupada;
- O veículo autônomo ocupado não pode ser atribuído à outra solicitação.

##### 4.2. Simulação 2

A Simulação 2 foi aplicada ao algoritmo multiobjetivo, sendo configurada assim:

- Os veículos, autônomos e pessoais, são distribuídos aleatoriamente no mapa. Durante todo o tempo de simulação, todos veículos podem entrar e sair da rede, simulando o fluxo de tráfego e interpretando o mapa como o recorte de uma região maior;
- No decorrer na simulação a proporção entre veículos autônomos livres e ocupados pode variar, simulando a existência de horários com maior número de solicitações;
- O veículo autônomo ocupado não pode ser atribuído à outra solicitação.

#### 5. Resultados e Discussões

##### 5.1. Tempo de Execução dos Algoritmos Genéticos Mono-Objetivo

Foram realizadas 30 execuções para cada versão dos algoritmos, incluindo a versão Gen, apresentada em [Alcântara & Pereira, 2019]. Nessa fase do trabalho, utilizou-se a

<sup>1</sup> <http://sumo.sourceforge.net/>

simulação 1. Usando ANOVA e teste de Tukey [Carrano et al 2011] tem-se a seguinte ordenação, do melhor para o pior: Gen-I, Gen-IIA, Gen-IIB, Gen-III e Gen. Os valores de distância foram próximos, de modo que Gen-I, Gen-IIA, Gen-IIB estão empatados e a GenIIA só é melhor que a Gen.

A Fig. 1 apresenta os resultados com relação ao tempo de execução dos algoritmos mono-objetivo. As novas versões foram comparadas com a Gen, constatando melhorias no tempo de execução bastante significativas. A versão Gen-IIA destacou-se com 90% de melhoria, seguida pela Gen-IIB com 88%, Gen-III com 81% e Gen-I com 65%.

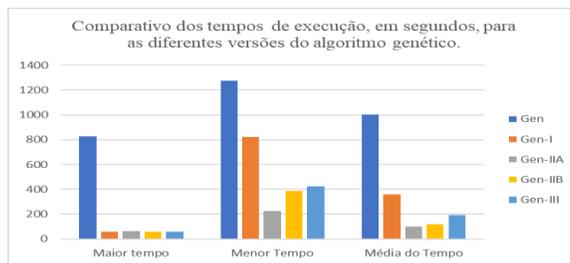


Figura. 1. Comparação dos tempos de execução das versões mono-objetivo.

## 5.2. Abordagem Multiobjetiva

Na abordagem multiobjetivo utilizou-se a Simulação 2, de modo que a complexidade do problema aumentou. Os valores esperados de distância de atendimento são maiores do que os esperados para a Simulação 1. Com a finalidade de comprovar a eficiência da proposta de minimização multi-objetivo, realizou-se testes de três abordagens distintas: algoritmo de minimização da distância, algoritmo de minimização do tempo de atendimento e algoritmo de minimização multiobjetivo. O algoritmo de minimização da distância usado foi proposto em [Alcântara & Pereira, 2019]; os demais foram desenvolvidos no presente estudo.

Devido ao aumento da complexidade da execução na simulação 2, utilizou-se quantidade máxima de gerações igual a 300 em todos os algoritmos. Realizou-se 30 repetições de cada algoritmo. Nas novas propostas aplicou-se os critérios de convergência estudados na versão Gen II-A.



Figura 2. Gráfico comparativo dos valores, normalizados, de distância e tempo de viagem, para cada tipo de minimização.

A eficiência do algoritmo de minimização multiobjetivo pode ser observada na Fig. 2. Comparando ao algoritmo [Alcântara & Pereira, 2019], minimização distância: (1) o algoritmo mono-objetivo de minimização do tempo de atendimento oferece melhoria de 14% no tempo de atendimento; em contrapartida uma piora em 12% na distância para atendimento; (2) o algoritmo multiobjetivo oferece 15% de melhoria no tempo para atendimento, sem melhorias significativas na distância para atendimento. O algoritmo multiobjetivo se destaca, ainda, no tempo de execução, pois a heurística de

parada utilizada na Gen-IIA também foi aplicada nele, desde modo não atinge o número máximo de gerações, diferente do algoritmo de minimização da distância, Gen.

## 6. Conclusão

O desenvolvimento de algoritmos que tenham respostas rápidas e eficientes e ainda assim retratem bem a complexa realidade do trânsito, otimizando a alocação de veículos, pode ser desafiador. Esse artigo apresentou formas alternativas de critérios de convergência em algoritmos genéticos focados na alocação de veículos autônomos. Esse tipo de método pode proporcionar redução no tempo de execução dos algoritmos. Outro ponto de contribuição consiste em um cenário mais abrangente que o apresentado em outros trabalhos: aqui é apresentado um algoritmo multiobjetivo capaz de minimizar a distância total percorrida pelos veículos e o tempo total de atendimento, consequentemente minimizando também a distância média percorrida pelos veículos para realizar o atendimento e o tempo médio para atendimento. Os resultados apresentam a minimização multiobjetivo como uma abordagem mais eficiente do que a abordagem mono-objetivo, dado o problema de alocação de veículos. Finalmente, destaca-se o estudo da evolução das gerações, inicialmente estudado no cenário mono-objetivo e posteriormente aplicada no cenário multiobjetivo, como um bom método para estabelecer critérios de convergência do algoritmo.

## Agradecimentos

Os autores agradecem ao CNPq e PROPE/UFSJ pelo suporte financeiro.

## Referências

- Alcântara, E. B., Pereira, M. A. (2019). A Genetic Algorithm to Autonomous Vehicles Designation. In GEOINFO 2019. pp. 194-199.
- Carrano, E. G., Wannner, E. F., Takahashi, R. H. (2011). A multicriteria statistical based comparison methodology for evaluating evolutionary algorithms. *IEEE Transactions on Evolutionary Computation*, 15(6):848–870.
- Fonseca, A. 7 empresas que estão desenvolvendo carros autônomos. (2020) Whow, 20 de março de 2020. Disponível em: < <https://www.whow.com.br/novas-tecnologias/7-empresas-desenvolvendo-carros-autonomos/>>. Acessado em 02/09/2020.
- Goldberg, D. E., Holland, J. H. (1988). Genetic algorithms and machine learning. *Machine learning*, 3(2):95–99.
- Gaspar - Cunha, A., Takashi, R., Antunes, C. H. (2013). Manual de computação evolutiva e metaheurística. Belo Horizonte: Editora UFMG.
- Kuhn, H. W. (1955). The Hungarian method for the assignment problem. *Naval research logistics quarterly*, 2(1-2), 83-97.
- Oliveira, A. A. M., Souza, M. P., Pereira, M. A., Reis, F. A. L., Almeida, P. E. M., Silva, E. J., Crepalde, D. S. (2015). Optimization of taxi cabs assignment in geographical location-based systems. In GEOINFO 2015, pp. 92-104.