



## **Algoritmos Evolutivos aplicados ao Problema de Transporte Multimodal**

**Júlia Borges Correia Silva**

Faculdade de Engenharia Elétrica e de Computação  
Universidade Estadual de Campinas  
julia@dt.fee.unicamp.br

**Priscila Cristina Berbert Rampazzo**

Faculdade de Ciências Aplicadas  
Universidade Estadual de Campinas  
priscila.rampazzo@fca.unicamp.br

**Akebo Yamakami**

Faculdade de Engenharia Elétrica e de Computação  
Universidade Estadual de Campinas  
akebo@dt.fee.unicamp.br

### **RESUMO**

Com o objetivo de tornar mais eficiente a mobilidade urbana, grandes cidades têm investido na diversidade e na conectividade dos meios de transporte. O Problema de Transporte Multimodal apresenta estratégias para otimizar rotas de uma origem até um destino usufruindo da interligação dos meios de transporte existentes. Neste trabalho foram implementadas três propostas para o tratamento do Problema de Transporte Multimodal, considerando a minimização do custo de transporte, a minimização do tempo de viagem e a minimização do número de trocas de modo de transporte. A primeira abordagem é uma adaptação de um algoritmo clássico de caminho mínimo considerando os múltiplos modos de transporte. A segunda e terceira abordagens são implementações de um Algoritmo Genético, no formato monobjetivo e multiobjetivo, respectivamente. Comparações entre as três abordagens foram realizadas com o intuito de motivar a consideração dos múltiplos objetivos.

**PALAVRAS CHAVE.** Transporte Multimodal, Algoritmo Genético, Otimização Multiobjetivo.

**Tópicos:** SS1, L&T, MH.

### **ABSTRACT**

In order to make urban mobility more efficient, large cities have invested in the diversity and connectivity of the means of transport. The Multimodal Transportation Problem presents tools to optimize routes from a source to a destination by making use of the interconnection of the existing means of transport. In this work three proposals were implemented for the treatment of multimodal transport problems, considering: transport costs minimization, travel time minimization and minimization of the transport mode exchanges number. The first approach is a classical algorithm adaptation, considering transport modes. The second and third approaches are implementations of a Genetic Algorithm, in the Monobjective and Multiobjective format, respectively. Comparisons between the three approaches were carried out, with the purpose of motivating the multiple objectives use.

**KEYWORDS.** Multimodal Transport, Genetic Algorithm, Multiobjective Optimization.

**Paper topics:** SS1, L&T, MH.



## 1. Introdução

O transporte é um dos principais fatores de produção e desenvolvimento econômico. O Problema de Transporte Multimodal encontra aplicações tanto em transporte de cargas, quanto em transporte de passageiros. Os serviços de transporte determinam o acesso das pessoas à educação, saúde, trabalho, lazer, etc. As empresas também dependem de meios de transporte para obter os insumos de seus fornecedores e levar seus produtos até os consumidores. Uma melhor gestão desses recursos permitirá que o transporte de passageiros e cargas seja mais eficiente [CNT, 2012].

A vantagem do Transporte Multimodal acontece pela combinação eficiente de vários tipos de transportes (modos) reduzindo os custos e com a melhor utilização e exploração da capacidade disponível. Mas para isso é necessário aprimorar o uso de cada modal individualmente, além de proceder à otimização do sistema global. Um estudo patrocinado pela *Rockefeller Foundation*<sup>1</sup> afirma que é necessário coordenar sistemas de locomoção multimodal que incluam as mais diversas opções em centros urbanos. Ações de priorização do transporte público multimodal têm sido propostas em grandes cidades [FIEP, 2010]. Porém, há problemas na utilização otimizada desses modos de transporte por existirem muitos parâmetros a serem considerados como, por exemplo, o tempo de percurso e a quantidade de vezes que o cidadão está apto a mudar de modo de transporte.

Dentre os trabalhos propostos na literatura, [Viedma, 2011] propõe a representação da rede de transporte multimodal através de grafos coloridos. Cada aresta do grafo possui múltiplos pesos e através de uma relação de ordenação parcial obtém-se um conjunto de caminhos Pareto-ótimos, através de uma adaptação do algoritmo clássico de Dijkstra. A aplicabilidade do algoritmo foi estudada em três casos reais de redes de transporte multimodal, da Nova Zelândia e da Europa. [Bastos, 2013] desenvolve um modelo computacional utilizando o algoritmo A\* [Ahuja e Magnanti, 1993] para determinação do melhor caminho considerando a distância percorrida e o número de modos de transporte necessários para percorrer dois pontos da cidade. O modelo proposto considera múltiplos critérios de decisão, como a distância total percorrida e o número de mudanças de modo de transporte, além de fornecer alguns detalhes sobre linhas de ônibus utilizadas, paradas e possíveis conexões. E, através de um estudo de caso do transporte público da cidade Porto Alegre, o modelo é avaliado utilizando dados reais. Os resultados foram comparados com o algoritmo de Dijkstra. [Dib et al., 2015] modela o problema considerando três modos de transporte: trem, ônibus e pedestre. O único objetivo é minimizar o tempo de viagem dado um horário de partida. Para resolver o problema é aplicado o Algoritmo Genético com um método também metaheurístico de busca local, o *Variable Neighborhood Search*. [Pino et al., 2010] apresentam um Algoritmo Genético para o problema de transporte multimodal de cargas, maximizando o volume de carga transportado entre origem e destino e garantindo assim a redução dos custos associados ao transporte e fretes. O trabalho de [Yu e Lu, 2010] apresenta uma solução para planejamento de rotas que utilizam-se de quatro modos de transporte: carro, ônibus, metrô e pedestre. A proposta se baseia na adaptação do algoritmo genético. O método de avaliação das soluções é multicritério, ou seja, a função de *fitness* é um vetor, onde cada dimensão está associada a um objetivo. Para determinação da solução ótima é utilizado o conceito de dominância proposto por [Goldberg, 1989]. O trabalho de [Massobrio et al., 2016] apresenta a aplicação de dois algoritmos evolutivos multiobjetivo ao problema de distribuir passageiros que viajam partindo da mesma origem à diferentes destinos, em vários táxis. O primeiro algoritmo segue uma abordagem de agregação linear dos objetivos; o segundo algoritmo é baseado no conceito de Pareto dominância. Ambos são comparados com duas heurísticas gulosas em 88 instâncias de dados reais, considerando os objetivos de minimização do custo total das viagens e de minimização dos atrasos de cada passageiro.

A maior parte dos trabalhos que tratam o problema de Transporte Multimodal considera o problema com um único objetivo, embora diferentes critérios possam ser interessantes para escolha e avaliação das soluções: minimização do custo da viagem, minimização da distância percorrida,

<sup>1</sup><http://www.rockefellerfoundation.org/>



minimização do número de trocas de modo de transporte, minimização do tempo total da viagem, etc. A incomensurabilidade dos objetivos e o possível conflito existente entre alguns destes critérios, incentiva a consideração simultânea e explícita de duas ou mais funções-objetivo.

De maneira geral, o objetivo deste projeto é analisar o Problema de Transporte Multimodal aplicado ao Tráfego Urbano, considerando três diferentes objetivos: a minimização do custo de transporte, a minimização do tempo de viagem e a minimização do número de trocas de modo de transporte. Para isto, três abordagens foram implementadas: uma adaptação do algoritmo clássico de Ford-Moore-Bellman [Ahuja e Magnanti, 1993] para caminho mínimo, considerando os múltiplos modos de transporte; um Algoritmo Genético [Bäck et al., 2000a,b] que considera o problema em seu formato monobjetivo e um Algoritmo Genético Multiobjetivo baseado em uma das propostas mais representativas do estado da arte da Otimização Multiobjetivo Evolutiva: *Non-dominated Sorting Genetic Algorithm II* (NSGA-II) [Deb et al., 2002].

## 2. Apresentação do Problema

O Problema do Transporte Multimodal pode ser abordado com um multigrafo direcionado e colorido  $G = (N, A, L)$ . Onde  $N$  é um conjunto finito de nós,  $A$  é um conjunto finito de arcos e  $L$  um conjunto finito de etiquetas distintas por cores. Os arcos são definidos como uma tripla  $(i, j, l)$  no domínio  $N \times N \times L$  com  $i, j \in N$  e  $l \in L$ . Para cada  $l \in L$ , é representado um modo de transporte. Dessa forma, um arco é determinado por um nó de origem, um nó de destino e uma etiqueta que caracteriza um meio de transporte.

As possíveis soluções para o problema consistem em um caminho que começa em uma origem e termina em um destino, pré-estabelecidos. Esse caminho é um conjunto de arcos que se conectam através de nós. Da Equação 1,  $x_{ijl}$  vale 1 quando o arco  $(i, j, l)$  pertence ao caminho e vale 0 quando não pertence. Cada solução possui três valores associados, cada um representando uma função-objetivo: o custo financeiro total do caminho, o tempo gasto para percorrê-lo e o número de mudanças de modo de transporte realizadas durante o percurso. Esses valores são calculados de acordo com as equações 2, 3 e 4, respectivamente.

A função  $f_1$  representa o custo total do caminho (Equação 2), ou seja, a somatória dos custos  $c_{ijl}$  dos arcos que pertencem ao caminho  $x_{ijl} = 1$ . Para calcular o tempo total de viagem do caminho (Equação 3), basta calcular  $f_2$  que é a somatória dos tempos  $t_{ijl}$  dos arcos que pertencem ao caminho  $x_{ijl} = 1$ . O algoritmo também detecta as mudanças de modo de transporte (Equação 4) de um caminho armazena a quantidade de trocas existentes em  $f_3$ .

$$x_{ijl} \in \{0, 1\} \quad \forall (i, j, l) \in A \quad (1)$$

$$f_1 = \sum_{(i,j,l) \in A} c_{ijl} x_{ijl} \quad (2)$$

$$f_2 = \sum_{(i,j,l) \in A} t_{ijl} x_{ijl} \quad (3)$$

$$f_3 = \sum_{\substack{x_{ijl_1}=1 \\ x_{jkl_2}=1 \\ l_1 \neq l_2 \\ (i,j,l_1) \in A \\ (i,j,l_2) \in A}} 1 \quad (4)$$

Estas definições foram utilizadas nas três abordagens que serão apresentadas a seguir.

## 3. Algoritmos Implementados

As três abordagens implementadas neste trabalho e utilizadas nas comparações estão descritas nas subseções a seguir. Os Algoritmos Genéticos possuem definições e operadores em comum, apresentados na Seção 3.2.



### 3.1. Adaptação de um Algoritmo Clássico

Com o intuito de validar os resultados obtidos pelos Algoritmos Genéticos (Seção 3.2), foi implementado o algoritmo clássico de Ford-Moore-Bellman [Bellman, 1956, 1957], com adaptação para a formulação de multimodal.

O Algoritmo de Ford-Moore-Bellman é baseado no *Princípio de Otimalidade de Bellman*:

*Uma estratégia ótima apresenta a propriedade segundo a qual, a despeito das decisões tomadas para se atingir um estado particular num certo estágio, as decisões restantes a partir deste estado devem constituir uma estratégia ótima. (Richard Bellman, 1957).*

Segundo essa metodologia, o custo mínimo  $v_j$  para se chegar a qualquer nó  $j \in N$  é definido pela Equação de Bellman para Caminho Mínimo:

$$v_j = \min\{v_j, \min(v_i + c_{ij})\}$$

tal que  $i$  pertence ao conjunto dos predecessores do nó  $j$ .

Por tratar-se de um método de otimização monobjetivo, primeiramente executamos o algoritmo com o objetivo de minimizar  $f_1$ , obtemos o caminho mínimo e avaliamos  $f_2$  e  $f_3$  neste caminho. Depois, executamos o algoritmo com o objetivo de minimizar  $f_2$ , obtemos o caminho mínimo e calculamos  $f_1$  e  $f_3$  neste caminho.

### 3.2. Algoritmos Genéticos

Algoritmos Genéticos são procedimentos computacionais para resolver problemas nas mais diversas áreas. Estes procedimentos são baseados na seguinte sequência [Bäck et al., 2000a,b] reprodução com herança genética (*crossover*), introdução de variações aleatórias através da mutação, competição e seleção dos indivíduos de uma dada população. Isto é realizado através de processos iterativos e cada iteração é chamada geração. No estágio de seleção, indivíduos com melhor desempenho têm maior chance de serem escolhidos para gerar novos indivíduos. Após o *crossover*, os novos indivíduos podem ser mutados para manter a diversidade genética da população. Embora possam parecer simplistas, estes algoritmos são suficientemente robustos para garantir um processo de busca eficiente.

A codificação (ou representação) dos indivíduos e a definição da função de adaptação (ou *fitness*) são as etapas mais importantes do algoritmo. Em problemas de otimização com restrições, a codificação adotada pode fazer com que indivíduos modificados sejam inactíveis. Logo, os operadores evolutivos dependem diretamente da definição do espaço de busca e da codificação do problema [Bäck et al., 2000b]. A seguir, serão apresentados os operadores implementados para as abordagens Evolutivas que serão analisadas neste trabalho, ambas baseadas em um Algoritmo Genético [Goldberg, 1989].

**Codificação:** O Problema de Transporte Multimodal é representado por um grafo direcionado em que os vértices são pontos de parada dos meios de transporte, terminais de integração entre eles ou pontos de origem e destino.

Um indivíduo (Figura 1) é representado por uma estrutura composta por uma lista ligada de números inteiros, que corresponde ao caminho percorrido desde a origem até o destino.

Os caminhos de dois indivíduos diferentes podem ter tamanhos diferentes, mas necessariamente o primeiro nó do caminho deve ser o da origem e o último o nó de destino. Todos os indivíduos gerados e modificados durante o algoritmo são factíveis.

**Inicialização e Avaliação da População:** Para gerar a população inicial, foi utilizado um algoritmo baseado no Algoritmo de *Ford-Moore-Bellman* [Bellman, 1956, 1957]. Os indivíduos




Figura 1: Indivíduo: um caminho ligando a origem ao destino.

da população original são frutos de uma série de execuções desse algoritmo onde cada execução gera um caminho e os custos das arestas são atribuídos aleatoriamente para cada execução. A escolha desse método justifica-se pela necessidade de gerar indivíduos factíveis e aleatórios. Após a inicialização, todos os indivíduos são avaliados através do cálculo das funções-objetivo:  $f_1$ ,  $f_2$  e  $f_3$ .

**Crossover:** O crossover utilizado pelo algoritmo é de apenas um ponto e tem cem por cento de chance de ocorrer. Dado dois indivíduos, o algoritmo procura nós em comuns entre seus caminhos, exceto a origem e o destino. Caso haja nó em comum, o crossover gera dois filhos diferentes dos pais, sendo o primeiro com a primeira parte do material genético vindo do primeiro pai e a segunda parte do segundo pai. O segundo filho terá a primeira parte do material genético do segundo pai e a segunda parte será do primeiro pai. Esse processo garante a factibilidade dos caminhos dos filhos gerados, portanto, caso não tenha nó em comum entre os dois pais, os filhos serão cópias do material genético dos pais.

**Mutação:** O operador que realiza a mutação nos indivíduos atua na mudança de um arco do caminho. A probabilidade de ocorrer mutação em um indivíduo é de dez por cento e todos os indivíduos tem a mesma probabilidade de passar pelo operador. Caso um indivíduo seja selecionado para sofrer mutação, é selecionado um nó aleatório do seu caminho, exceto a origem e o destino. Para garantir a manutenção da factibilidade, procura-se um novo arco existente no grafo que substitua o arco que chega ou que sai daquele nó, sem modificar os outros nós do caminho. O algoritmo dá preferência em modificar os arcos de forma que o modo de transporte não mude. Ou seja, se o modo de chegada ao nó sorteado é diferente do modo de saída e houver no grafo um arco do mesmo modo do arco que chega, o algoritmo fará a mudança para esse arco. Esse processo depende da existência de arcos no grafo para realizar a troca, portanto, não é sempre que um indivíduo, mesmo que selecionado para sofrer mutação, de fato tem seu código genético mutado. Outros operadores de mutação e crossover estão sendo estudados e serão objetos de pesquisas futuras.

A população atual  $P_g$  é formada por  $LP$  indivíduos. Seleção (apresentadas nas Seções 3.2.1 e 3.2.2), *crossover* e mutação são operadores aplicados em  $P_g$  para criar a população de filhos  $Q_g$ , também de tamanho  $LP$ . A seleção é realizada através de torneio binário [Bäck et al., 2000b]. Primeiro, são amostradas aleatoriamente duas soluções de  $P_g$  e comparadas de acordo com os critérios de Seleção de cada abordagem. Pares de soluções selecionadas são aleatoriamente formados. Estes pares podem passar por crossover e mutação, de acordo com as respectivas probabilidades, para formar a população de filhos  $Q_g$ . Uma população mista  $R_g = P_g \cup Q_g$ , de tamanho  $2 * LP$ , é ordenada de acordo com os critérios de Seleção para escolhermos exatamente  $LP$  indivíduos para a nova população  $P_{g+1}$ .

### 3.2.1. Abordagem Monobjetivo

Os operadores específicos para esta abordagem estão descritos a seguir.

**Função de Adaptação (Fitness):** No algoritmo desenvolvido para a formulação monobjetivo, considerou-se a minimização de uma das funções  $f_1$ ,  $f_2$  ou  $f_3$  como medida de desempenho ou adaptação (*fitness*) de cada indivíduo. A população é ordenada em ordem crescente segundo



uma destas funções (todas as funções-objetivo do problema são de minimização).

**Seleção:** Todos os indivíduos (soluções factíveis) podem ser selecionados. O processo de seleção é realizado através de torneio. Ou seja, dois indivíduos são selecionados aleatoriamente para competirem; aquele que possuir o melhor *fitness* será escolhido para compor o conjunto dos pais. Pares de pais são formados, aleatoriamente, com os indivíduos da seleção que passaram pelo torneio; estes pares podem passar pelo cruzamento e pela mutação, dependendo das probabilidades associadas a estes operadores. As soluções finais são os melhores indivíduos das gerações, que evoluíram carregando fortes características e obtiveram os melhores desempenhos, ou seja, soluções factíveis com os melhores valores para a função-objetivo adotada.

### 3.2.2. Abordagem Multiobjetivo

A maioria dos trabalhos trata o problema com um unico objetivo, geralmente  $f_1$  ou  $f_2$ . O resultado disto, é a obtenção de soluções extremas, que minimizam apenas um objetivo, sem levar outros interesses em consideração. Em Otimização Multiobjetivo, otimizar significa encontrar valores aceitáveis para as funções-objetivo para uma tomada de decisão, Nesta situação, se quaisquer componentes de  $[f_1, f_2, f_3]$  competirem, não existirá uma solução única para o problema e sim um conjunto de soluções de compromisso (*trade-off*), ou seja, o conjunto de soluções não-dominadas, nas quais uma melhora em um dos objetivos resulta em degradação de outro(s).

O espaço de busca de um problema de Otimização Multiobjetivo é parcialmente ordenado, no sentido de que duas soluções arbitrárias são relacionadas de duas possíveis maneiras: ou uma domina a outra ou nenhuma delas domina [Sawaragi et al., 1985; Abraham e Jain, 2005]. Dado um conjunto não-dominado de soluções (possíveis caminhos) é possível definir a fronteira não-dominada (valores de  $[f_1, f_2, f_3]$  associados a cada caminho não-dominado).

Admite-se que não são conhecidas informações de preferências entre os objetivos, de forma que o algoritmo deve gerar alternativas para a posterior escolha do usuário (decisor). O algoritmo implementado para a formulação multiobjetivo [J. B. C. Silva, 2017] foi baseado na abordagem de ordenação não-dominada proposta no algoritmo NSGA-II [Deb et al., 2000, 2002], e os principais operadores estão descritos a seguir.

**Seleção: Ordenação não-dominada e Distância de Aglomeração:** Na geração  $g$ , todo indivíduo  $i$  da população é associado a dois atributos: classificação não-dominada  $rank_i$  e distância de aglomeração  $dist_i$ . Como definido no NSGA-II [Deb et al., 2000, 2002], se duas soluções  $i_1$  e  $i_2$  estão em diferentes fronteiras não-dominadas ( $rank_{i_1} \neq rank_{i_2}$ ), prefere-se a solução com menor classificação (Figura 2). Por outro lado, se ambas as soluções pertencem à mesma fronteira, preferimos a solução que está localizada na região menos cheia (com menor  $dist_i$ ).

## 4. Resultados

A instância utilizada nas execuções do algoritmo foi baseada no mapa de uma região da ilha de Manhattan. Foram adotados quatro modos de transporte: metrô, ônibus, pedestre e carro. Cada modo de transporte corresponde a um subgrafo e a união desses subgrafos representa o grafo da instância completa. A instância possui 54 nós e 632 arcos direcionados. Cada arco possui um custo financeiro associado e um tempo correspondente à estimativa de quanto demorado é para percorrer determinado trecho por um dado meio de transporte. Esses valores foram normalizados para ficarem entre 0 e 10. Os modos de transporte são identificados com a seguinte numeração: 1 - metrô, 2 - ônibus, 3 - pedestre, 4 - carro. Consideramos ainda a seguinte numeração: origem = 1 e destino = 52.

Primeiramente, executamos o algoritmo clássico adaptado (Seção 3.1) com o objetivo de minimizar  $f_1$ , obtivemos o caminho mínimo associado e avaliamos  $f_2$  e  $f_3$  neste caminho (primeira




Figura 2: Ordenação não-dominada: minimização de duas funções-objetivo.

$f_1$	$f_2$	$f_3$	<b>caminhos</b>
<b>0</b>	100	0	(1, -)→(2, 3)→(6, 3)→(10, 3)→(16, 3)→(26, 3)→(32, 3)→(38, 3)→(40, 3)→(42, 3)→(52, 3)
45	<b>10</b>	0	(1, -)→(3, 4)→(17, 4)→(33, 2)→(44, 4)→(52, 4)

Tabela 1: Resultados do algoritmo clássico adaptado.

linha, Tabela 1). Depois, executamos o mesmo algoritmo com o objetivo de minimizar  $f_2$ , obtivemos o caminho mínimo associado e calculamos  $f_1$  e  $f_3$  neste caminho (segunda linha, Tabela 1).

A natureza estocástica dos algoritmos evolutivos faz com que seja necessário a realização de uma série de execuções para validação dos resultados. Para este estudo, 30 rodadas de testes foram executadas, para ambos os Algoritmos Genéticos.

Para a abordagem multiobjetivo, o tamanho da população foi de  $LP = 150$  indivíduos e o número de gerações  $G = 600$ ; as taxas de mutação e crossover consideradas são:  $PM = 0.1$  e  $PC = 1$ . Estes valores foram determinados empiricamente em um trabalho anterior ([J. B. C. Silva, 2017]), levando-se em consideração a quantidade de soluções não-dominadas e o seu espalhamento na última geração. Para a abordagem monoobjetivo, considerou-se o número de gerações  $G = 100$  (baseado no comportamento da média da função-objetivo considerada); os demais parâmetros ( $LP$ ,  $PM$  e  $PC$ ) foram considerados iguais aos da abordagem multiobjetivo.

Na segunda etapa, executamos o algoritmo evolutivo com formulação mono-objetivo (Seção 3.2.1) com o objetivo de minimizar  $f_1$ , obtivemos os caminhos associados a cada indivíduo da população e avaliamos  $f_2$  e  $f_3$  nestes caminhos (Caso 1). Depois, executamos o mesmo algoritmo com o objetivo de minimizar  $f_2$ , obtivemos os caminhos associados e calculamos  $f_1$  e  $f_3$  nestes caminhos (Caso 2). E finalmente, executamos o mesmo algoritmo com o objetivo de minimizar  $f_3$ , obtivemos os caminhos associado e calculamos  $f_1$  e  $f_2$  referentes a estes caminhos (Caso 3). As Tabelas 2, 3, 4 apresentam os resultados dos respectivos Casos 1, 2 e 3, com a melhor solução da última geração (todas as 30 rodadas de testes de cada caso chegaram à estas soluções).

A Figura 3 mostra as fronteiras não-dominadas obtidas nas 30 execuções, com a abordagem multiobjetivo [J. B. C. Silva, 2017]. É possível verificar o comportamento conflitante entre os

$f_1$	$f_2$	$f_3$	<b>caminho</b>
<b>0</b>	70	0	(1, -)→(3, 3)→(6, 3)→(17, 3)→(33, 3)→(43, 3)→(42, 3)→(52, 3)

Tabela 2: Resultados do algoritmo evolutivo mono-objetivo - Caso 1.



$f_1$	$f_2$	$f_3$	<b>caminhos</b>
45	<b>10</b>	0	(1, -)→(3, 4)→(17, 4)→(45, 4)→(44, 4)→(52, 4) (1, -)→(3, 4)→(17, 4)→(33, 4)→(44, 4)→(52, 4)

Tabela 3: Resultados do algoritmo evolutivo mono-objetivo - Caso 2.

$f_1$	$f_2$	$f_3$	<b>caminhos</b>
45	10	<b>0</b>	(1, -)→(3, 4)→(17, 4)→(45, 4)→(44, 4)→(52, 4) (1, -)→(3, 4)→(17, 4)→(33, 4)→(44, 4)→(52, 4)

Tabela 4: Resultados do algoritmo evolutivo mono-objetivo - Caso 3.

objetivos  $f_1$  e  $f_2$  (Figura 3), embora não se tenha identificado conflito destes com o objetivo  $f_3$ .




Figura 3: Fronteiras não-dominadas -  $f_1$  x  $f_2$ .

A Tabela 5 apresenta as soluções não-dominadas, dentre todas as soluções não-dominadas obtidas nas 30 execuções do algoritmo evolutivo multiobjetivo. Em média, o algoritmo inicia com 16 indivíduos na primeira fronteira não-dominada (na população inicial) e finaliza com a média de 146 indivíduos na primeira fronteira. Cada tupla representa: (número do nó, modo de chegada neste nó). Em alguns casos, os mesmos valores de função-objetivo são mapeamentos de diferentes caminhos, destacando a capacidade do algoritmo de encontrar soluções alternativas, associadas aos mesmos valores de  $f_1$ ,  $f_2$  e  $f_3$ .

Percebe-se que nas soluções intermediárias que acontecem a maior quantidade de troca de modos. As soluções extremas estão associadas a caminhos sem troca de modo de transporte, embora a troca de modo não tenha sido penalizada com acréscimo de custo ou tempo de viagem. Observa-se também, que a minimização de  $f_1$  leva a soluções com maior número de nós visitados. Enquanto que, na direção de minimização  $f_2$ , o número de nós visitados nos caminhos diminuem. Deste resultado, percebemos que, se desejarmos incentivar o uso de múltiplos modos de transporte em centros urbanos, as soluções intermediárias da fronteira não-dominada apresentam a maior variabilidade de modos de transporte em um caminho. Soluções estas, que possuem a mesma qualidade que as soluções extremas, do ponto de vista da Otimização Multiobjetivo, que as soluções extremas (que minimizam apenas um dos objetivos).





$f_1$	$f_2$	$f_3$	<b>caminhos</b>
0	70	0	(1, -)→(3, 3)→(6, 3)→(17, 3)→(33, 3)→(43, 3)→(42, 3)→(52, 3) (1, -)→(2, 3)→(6, 3)→(17, 3)→(33, 3)→(43, 3)→(42, 3)→(52, 3)
4	65	1	(1, -)→(12, 1)→(22, 3)→(35, 3)→(38, 3)→(40, 3)→(51, 3)→(52, 3) (1, -)→(12, 1)→(22, 3)→(35, 3)→(38, 3)→(40, 3)→(42, 3)→(52, 3) (1, -)→(3, 3)→(6, 3)→(17, 3)→(33, 3)→(43, 3)→(41, 3)→(52, 1) (1, -)→(2, 3)→(6, 3)→(17, 3)→(33, 3)→(43, 3)→(41, 3)→(52, 1) (1, -)→(2, 3)→(12, 3)→(22, 3)→(35, 3)→(38, 3)→(41, 3)→(52, 1) (1, -)→(3, 3)→(6, 3)→(17, 3)→(33, 3)→(32, 3)→(41, 3)→(52, 1)
8	50	2	(1, -)→(12, 1)→(22, 3)→(35, 3)→(38, 3)→(41, 3)→(52, 1)
12	45	2	(1, -)→(12, 1)→(22, 1)→(35, 3)→(38, 3)→(41, 3)→(52, 1)
16	40	2	(1, -)→(12, 1)→(22, 1)→(35, 1)→(38, 3)→(41, 3)→(52, 1)
20	37	3	(1, -)→(12, 1)→(22, 1)→(35, 1)→(38, 2)→(41, 3)→(52, 1) (1, -)→(12, 1)→(22, 1)→(35, 1)→(38, 3)→(41, 4)→(52, 1)
25	32	3	(1, -)→(12, 1)→(22, 1)→(35, 1)→(38, 3)→(41, 4)→(52, 1)
27	26	3	(1, -)→(3, 3)→(17, 4)→(33, 3)→(44, 4)→(52, 4)
31	23	3	(1, -)→(3, 3)→(17, 4)→(33, 2)→(44, 4)→(52, 4)
36	18	1	(1, -)→(3, 4)→(17, 4)→(33, 3)→(44, 4)→(52, 4) (1, -)→(3, 3)→(17, 4)→(33, 4)→(44, 4)→(52, 4)
40	15	2	(1, -)→(3, 4)→(17, 4)→(33, 2)→(44, 4)→(52, 4)
45	10	0	(1, -)→(3, 4)→(17, 4)→(33, 4)→(44, 4)→(52, 4) (1, -)→(3, 4)→(17, 4)→(45, 4)→(44, 4)→(52, 4)

Tabela 5: Soluções não-dominadas: algoritmo evolutivo multiobjetivo.

Observamos que o algoritmo evolutivo multiobjetivo conseguiu obter as soluções extremas referentes à minimização de cada objetivo separadamente:  $f_1 = 0$  e  $f_2 = 10$  (Tabelas 2 e 3). E mais, analisando o extremo referente à minimização de  $f_1$ , a solução do algoritmo multiobjetivo ( $f_1 = 0, f_2 = 70, f_3 = 0$ ) domina a solução do algoritmo clássico adaptado ( $f_1 = 0, f_2 = 100, f_3 = 0$ ).

## 5. Conclusão

Neste trabalho apresentamos os resultados de três abordagens para o Problema de Transporte Multimodal: uma adaptação do Algoritmo de Ford-Moore-Bellman para uma rede com múltiplos modos de transporte, uma abordagem baseada em Algoritmo Genético para a formulação com um único objeto e uma abordagem baseada no NSGA-II [Deb et al., 2002] para a formulação que considera explicitamente e simultaneamente os múltiplos objetivos do problema.

A consideração de modelos de Otimização Multiobjetivo refletem melhor uma realidade complexa e possibilita a exploração de uma gama maior de soluções alternativas. O usuário pode optar por uma solução com tempos e custos intermediários, por exemplo; já que, geralmente, uma solução de custo financeiro mínimo, pode ser a solução com maior tempo de viagem. Esta é a principal motivação para a consideração do Problema de Transporte Multimodal em sua forma Multiobjetivo: a consideração simultânea de múltiplos objetivos, com a implementação de uma abordagem que possa apresentar um conjunto de alternativas para posterior escolha, de acordo com os interesses do usuário.

Para auxiliar o processo de tomada de decisão, um Modelo de Tomada de Decisão Multicritério (Análise Envoltória de Dados) será aplicado pós-otimização para avaliar as soluções não-dominadas obtidas pelo Algoritmo Genético Multiobjetivo, com o intuito de encontrar as soluções



mais eficientes. Com este método será possível avaliar como variações e incertezas da rede afetam a eficiência das soluções, direcionando o usuário no processo decisório.

Trabalhos futuros também incluem a consideração de situações mais complexas, como o fluxo de veículos em tempo real. Por exemplo, se eventualmente houver um atraso ou interrupção do tráfego em determinado local, a solução consideraria essa restrição. Essa perspectiva seria possível se o fornecimento de informações consistir de uma rede que interliga os provedores de dados das condições de trânsito dos diferentes modos de transporte existentes.

Além da aplicação do algoritmo proposto em problemas de Tráfego Urbano, outras aplicações importantes podem valer-se da proposta apresentada neste trabalho. A consideração de rotas multimodais pode ser vantajosa em diversas situações, como nos casos de escoamento de produtos agrícolas para exportação. Entretanto, a possibilidade de redução dos custos logísticos está condicionada à existência de transbordo de carga (mudança de modo) e da integração entre os modais disponíveis [do Amaral et al., 2012]. Nesse contexto, vislumbra-se a aplicação do algoritmo proposto em problemas reais e importantes para sociedade.

## Referências

- Abraham, A. e Jain, L. (2005). *Evolutionary Multiobjective Optimization: Theoretical Advances and Applications*, chapter Evolutionary Multiobjective Optimization, p. 1–6. Springer-Verlag, Londres, 1 edition.
- Ahuja, T. L. e Magnanti, R. K. (1993). *Network Flows*. Prentice Hall, Philadelphia, Pennsylvania.
- Bäck, T., Fogel, D. B., e Michalewicz, Z. (2000a). *Evolutionary Computation 1: Basic Algorithms and Operators*. Institute of Physics Publishing, Bristol, UK, 1 edition.
- Bäck, T., Fogel, D. B., e Michalewicz, Z. (2000b). *Evolutionary Computation 2: Advanced Algorithms and Operators*. Institute of Physics Publishing, Bristol, UK, 1 edition.
- Bastos, R. (2013). Determinação de caminhos mínimos em aplicações de transporte público: um estudo de caso para a cidade de porto alegre. Master's thesis, Universidade do Vale do Rio dos Sinos, São Leopoldo.
- Bellman, R. (1956). *On a Routing Problem*. P (Rand Corporation). Rand Corporation. URL <https://books.google.com.br/books?id=nfbUHAAACAAJ>.
- Bellman, R. E. (1957). *Dynamic Programming*. Princeton University Press, New Jersey, USA, 1 edition.
- CNT (2012). A importância do setor de transporte. *Economia em Foco – Confederação Nacional do Transporte*.
- Deb, K., Agarwal, S., Pratap, A., e Meyarivan, T. (2002). A fast and elitist multi-objective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2):182–197.
- Deb, K., Agrawal, S., Pratap, A., e Meyarivan, T. (2000). A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: NSGA-II. In *Proceedings of VI Conference Parallel Problem Solving from Nature*, volume 1917, p. 849–858, Paris, France. Springer-Verlag.
- Dib, O., Manier, M., e Caminada, A. (2015). Memetic algorithm for computing shortest paths in multimodal transportation networks. *Elsevier B.V.*, 10:745–755.



- do Amaral, M., Almeida, M. S., e Morabito, R. (2012). Um modelo de fluxos e localização de terminais intermodais para escoamento da soja brasileira destinada à exportação. *Gest. Prod.*, 19 (2):717–732.
- FIEP (2010). Cidades inovadoras: Transporte e mobilidade – Federação das Indústrias do Estado do Paraná. URL <http://www.cidadesinovadoras.org.br/curitiba2030/transporte-e-mobilidade---objetivo-2-1-12503-110045.shtml>.
- Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA, 1st edition. ISBN 0201157675.
- J. B. C. Silva, A. Y., P. C. B. Rampazzo (2017). Evolutionary multi-objective optimization for the multimodal transport problem. In *Proceedings of MIC 2017: The XI Metaheuristics International Conference*, p. 1–10, Barcelona, Espanha.
- Massobrio, R., Fagundez, G., e Nesmachnow, S. (2016). Multiobjective evolutionary algorithms for the taxi sharing problem. *International Journal of Metaheuristics*, 5(1):67–90.
- Pino, R., de la Fuente, D., e I. Fernandez, N. G. (2010). Optimization del llenado de contenedores para transporte multimodal. In *4th International Conference on Industrial Engineering and Industrial Management*, Donostia - San Sebastian.
- Sawaragi, Y., Nakayama, H., e Tanino, T. (1985). *Theory of Multiobjective Optimization*. Academic Press, Orlando, Florida, USA, 1 edition.
- Viedma, F. E. L. (2011). *Coloured-edge graph approach for the modelling of multimodal networks*. PhD thesis, Auckland University of Technology, New Zealand.
- Yu, H. e Lu, F. (2010). A multi-modal route planning approach with an improved genetic algorithm. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38:343–348.